

UNIVERSIDADE FEDERAL DO PARANÁ

SAMUEL BELLIDO RODRIGUES

MÉTODO HÍBRIDO ITERATIVO SARIMA *SUPPORT VECTOR REGRESSION*
WAVELET DE MÚLTIPLOS NÚCLEOS NA PREVISÃO DE SÉRIES TEMPORAIS
DE INSTRUMENTOS DE BARRAGENS

CURITIBA
2015

SAMUEL BELLIDO RODRIGUES

MÉTODO HÍBRIDO ITERATIVO SARIMA *SUPPORT VECTOR REGRESSION*
WAVELET DE MÚLTIPLOS NÚCLEOS NA PREVISÃO DE SÉRIES TEMPORAIS
DE INSTRUMENTOS DE BARRAGENS

Tese apresentada ao Programa de Pós-Graduação em Métodos Numéricos em Engenharia na área de concentração de Programação Matemática, dos setores de Tecnologia e de Ciências Exatas da Universidade Federal do Paraná, como requisito parcial à obtenção do grau de Doutor.

Orientador: Prof. Dr. Arinei Carlos Lindbeck da Silva.

Coorientador: Prof. Dr. Luiz Albino Teixeira Júnior.

CURITIBA
2015

R696m

Rodrigues, Samuel Bellido

Método híbrido iterativo Sarima Support Vector Regression Wavelet de múltiplos núcleos na previsão de séries temporais de instrumentos de barragens/ Samuel Bellido Rodrigues. – Curitiba, 2015.

93 f. : il. color. ; 30 cm.

Tese - Universidade Federal do Paraná, Setor de Ciências Exatas, Programa de Pós-graduação em Métodos Numéricos em Engenharia, 2015.

Orientador: Arinei Carlos Lindbeck da Silva – Co-orientador: Luiz Albino Teixeira Júnior.

Bibliografia: p. 82-93.

1. Análise de séries temporais - Predição. 2. Barragens de concreto - Instrumentação. 3. Programação (Matemática). I. Universidade Federal do Paraná. II. Silva, Arinei Carlos Lindbeck da. III. Teixeira Júnior, Luiz Albino . IV. Título.

CDD: 519.55

TERMO DE APROVAÇÃO

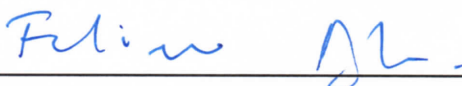
SAMUEL BELLIDO RODRIGUES

MÉTODO HÍBRIDO ITERATIVO SARIMA – SUPPORT VECTOR REGRESSION
WAVELET DE MÚLTIPLOS NÚCLEOS NA PREVISÃO DE SÉRIES TEMPORAIS DE
INSTRUMENTOS DE BARRAGENS

Tese aprovada como requisito parcial para obtenção do grau de doutor no Programa de Pós-Graduação em Métodos Numéricos em Engenharia, da Universidade Federal do Paraná, pela seguinte banca examinadora:



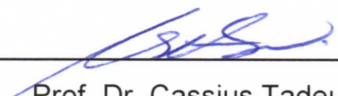
Prof. Dr. Arinei Carlos Lindbeck da Silva
Orientador – membro do PPGMNE/UFPR



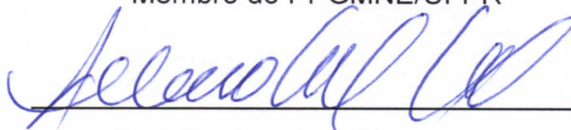
Prof. Dr. Fabiano Oscar Drozda
Membro do PPGEF/UFPR

(participação por vídeo conferencia)

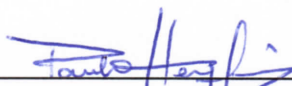
Prof. Dr. Rafael Moraes de Souza
Membro da UFMG



Prof. Dr. Cassius Tadeu Scarpin
Membro do PPGMNE/UFPR



Prof. Dr. Anselmo Chaves Neto
Membro do PPGMNE/UFPR



Prof. Dr. Paulo Henrique Siqueira
Membro do PPGMNE/UFPR

Curitiba, 22 de dezembro de 2015.

Dedico este trabalho a Deus,
O Supremo Criador e Único Salvador.

A minha filha Anna.
Minha eterna princesinha.

À minha esposa Angelina,
Companheira de todas as horas.

AGRADECIMENTOS

Aos professores Arinei Carlos Lindbeck da Silva e Luiz Albino Teixeira Junior pelas orientações e conhecimentos repassados. Por serem exemplos na pesquisa, educação e como pessoas possuidoras de valores imprescindíveis ao ser humano.

À professora Liliana Madalena Gramani pelos seus esforços ao longo do curso, orientações e cobranças que atuaram de forma motivadora nos impulsionando para frente.

Ao professor Anselmo Chaves Neto, pelos ensinamentos, incentivos e momentos de descontração nesta árdua caminhada.

Aos professores Cassius Tadeu Scarpin, Neida Maria Patias Volpi e Paulo Henrique Siqueira pelos ensinamentos.

À minha família, especialmente à minha esposa Angelina Patrícia e à minha filha Anna Julia por entenderem a minha ausência durante o curso, aos meus pais, José Edmundo e Madalena, aos meus irmãos Otoni e Oséias pelo apoio, em todos os momentos.

Aos engenheiros Dimilson Pinto Coelho, Cláudio Issamy Osako e Cláudio Neumann Júnior, pelo auxílio nos assuntos técnicos.

À Alexandra da Silva pela atenção dispensada e pelos encaminhamentos e busca de soluções nos obstáculos da caminhada.

A Universidade Federal do Paraná, Universidade Estadual do Oeste do Paraná, Itaipu, CEASB e todas as pessoas que contribuíram para a viabilização do Doutorado.

Aos amigos e colegas do curso, especialmente aqueles que não faltaram com uma palavra amiga nos momentos difíceis.

À Universidade Tecnológica Federal do Paraná, a qual sou filiado. Aos integrantes do Departamento de Matemática. Aos meus amigos Levi Lopes Teixeira e Jairo Marlon Corrêa pelas sugestões, incentivos e relevantes contribuições.

RESUMO

Nesta tese de Doutorado é apresentado um novo método preditivo híbrido, formado basicamente pela combinação dos métodos SARIMA, *Support Vector Regression* e *Wavelet*, denominado como SARIMA *Support Vector Regression Wavelet* de Múltiplos Núcleos (SSVRWMN), para a predição de valores de leitura de instrumentos de barragens de concreto de usinas hidroelétricas. Tendo as previsões pontuais, estima-se o intervalo de confiança por meio da técnica *Bootstrap*. O método SSVRWMN *Bootstrap* contempla as seguintes abordagens: os modelos SARIMA (para mapear estruturas de autodependência lineares sazonais e simples); a decomposição *Wavelet* integrada com modelos *Support Vector Regression* (SVRs) (que mapeiam estruturas de autodependência não lineares e da frequência espectral inerente aos dados); a programação não linear (utilizada no ajuste numérico dos parâmetros associados às combinações de previsões) e a técnica *Bootstrap* aplicada aos resíduos do modelo SSVRWMN com a finalidade de se estimar o intervalo de confiança *Bootstrap*. O objetivo é produzir previsões para as séries temporais provenientes de instrumentos de barragens, agregadoras de informações estocásticas distintas capturadas por diferentes métodos. A fim de avaliar a eficiência do método preditivo SSVRWMN, este foi aplicado a algumas séries temporais provenientes da aferição de instrumentos situados no bloco-chave I10 da barragem de Itaipu (as quais são utilizadas na análise probabilística de risco de tombamento dos blocos no sentido montante-jusante). O desempenho preditivo alcançado pelo método SSVRWMN, em relação aos métodos preditivos SARIMA, SVR e composto SARIMA-SVR, foi notadamente superior, na presente tese.

Palavras-chave: Séries temporais, Instrumentação de barragens, SARIMA, *Wavelet*, *Support Vector Regression*, Programação matemática, Técnica *Bootstrap*.

ABSTRACT

In this doctoral thesis is presented a new hybrid predictive method, formed by the combination of the methods SARIMA, Support Vector Regression and Wavelet referred as: SARIMA Support Vector Regression Wavelet of multiple kernels (SSVRWMN), for the prediction of reading values of concrete dams of hydroelectric plants. With the forecasts, it is estimated the confidence interval by Bootstrap technique. The method SSVRWMN Bootstrap includes the following approaches: SARIMA models (to map linear auto-dependence structures simple and seasonal); Wavelet decomposition integrated with Support Vector Regression models (SVR) (which map non-linear auto-dependence structures and spectral frequency inherent to data); nonlinear programming (used in the numerical adjustment of the parameters associated with combinations of forecasts) and the Bootstrap residual technique applied to residue the model SSVRWMN in order to estimate the Bootstrap confidence interval. The goal is to produce forecasts for the time series from instruments of dams that are aggregators of distinctive stochastic information captured by different methods. In order to evaluate the efficiency of method SSVRWMN predictive, this was applied to some time series from instruments located in block-key I10, of Itaipu Dam (which are used in probabilistic analysis tipover risk of blocks in the downstream-upstream direction). The predictive performance achieved by SSVRWMN concerning the traditional approaches SARIMA, SVR and composed SARIMA-SVR, have been remarkable superior.

Keywords: Time series, dam Instrumentation, SARIMA, *Wavelet*, *Support Vector Regression*, Mathematical programming, *Bootstrap* Technique.

LISTA DE FIGURAS

FIGURA 1 - FLUXOGRAMA COM AS ETAPAS DO MÉTODO PROPOSTO	19
FIGURA 2 - FUNÇÃO DE APROXIMAÇÃO (LADO ESQUERDO), FUNÇÃO DE PERDA (LADO DIREITO)	27
FIGURA 3 - LOCALIZAÇÃO DO TRECHO I	37
FIGURA 4 - MOVIMENTO DE TOMBAMENTO	38
FIGURA 5 - LOCALIZAÇÃO DOS INSTRUMENTOS NO BLOCO I10	39
FIGURA 6 - SÉRIE TEMPORAL CO-I-2/X PERÍODO 1994 A 2014	41
FIGURA 7 - SÉRIE TEMPORAL PS-I-22 PERÍODO 1994 A 2014	42
FIGURA 8 - SÉRIE TEMPORAL JS-I-31/DESLIZ E JS-I-32/ASENTAMENTO PERÍODO 1994 A 2014.....	43
FIGURA 9 - SÉRIE TEMPORAL EM-I-7/1 E EM-I-9/1 PERÍODO 1994 A 2014.....	44
FIGURA 10 - DECOMPOSIÇÃO <i>WAVELET</i> DA SÉRIE OBSERVADA	48
FIGURA 11 - MÉTODO <i>SUPPORT VECTOR REGRESSION</i> DE MÚLTIPLOS NÚCLEOS - SVRMN	49
FIGURA 12 - PREVISÃO DAS COMPONENTES <i>WAVELET</i> POR SVRMN.....	51
FIGURA 13 - FLUXOGRAMA DO MÉTODO HÍBRIDO PROPOSTO SSVRWMN....	54
FIGURA 14 - GRÁFICO DA SÉRIE DO PÊNDULO E PREVISÕES PELO MÉTODO SSVRWMN.....	60
FIGURA 15 - INTERVALO DE CONFIANÇA PARA A SÉRIE TEMPORAL CO-I-2/X	62
FIGURA 16 - GRÁFICO DA SÉRIE DO PIEZÔMETRO E PREVISÕES PELO MÉTODO SSVRWMN.....	65
FIGURA 17 - INTERVALO DE CONFIANÇA PARA A SÉRIE TEMPORAL PS-I-22.	66
FIGURA 18 - GRÁFICO DA SÉRIE JS-I-31/D E PREVISÕES PELO MÉTODO SSVRWMN.....	70
FIGURA 19 - GRÁFICO DA SÉRIE JS-I-32/A E PREVISÕES PELO MÉTODO SSVRWMN.....	71
FIGURA 20 - INTERVALO DE CONFIANÇA PARA A SÉRIE TEMPORAL JS-I- 31/DESLIZAMENTO.....	72
FIGURA 21 - INTERVALO DE CONFIANÇA PARA A SÉRIE TEMPORAL JS-I- 32/ASENTAMENTO.....	73

FIGURA 22 - GRÁFICO DA SÉRIE EM-I-7-1 E PREVISÕES PELO MÉTODO SSVRWMN.....	77
FIGURA 23 - GRÁFICO DA SÉRIE EM-I-9-1 E PREVISÕES PELO MÉTODO SSVRWMN.....	77
FIGURA 24 - INTERVALO DE CONFIANÇA PARA A SÉRIE TEMPORAL EM-I-7-1	79
FIGURA 25 - INTERVALO DE CONFIANÇA PARA A SÉRIE TEMPORAL EM-I-9-1	79

LISTA DE TABELAS

TABELA 1 - CARACTERÍSTICAS DAS FAMÍLIAS <i>WAVELET</i>	47
TABELA 2 - MODELAGEM SARIMA CO-I-2/X	56
TABELA 3 - SÉRIES MODELADAS VIA SVRMN	57
TABELA 4 - DOIS MELHORES RESULTADOS PARA CADA FAMÍLIA <i>WAVELET</i> (CO-I-2/X).....	58
TABELA 5 - PARÂMETROS SVR	59
TABELA 6 - COMPARATIVO MSE, MAPE E MAE PARA A SÉRIE CO-I-2/X <i>MULTI</i> <i>STEP H= 12</i>	61
TABELA 7 - MODELAGEM SARIMA PS-I-22	63
TABELA 8 - DOIS MELHORES RESULTADOS PARA CADA FAMÍLIA <i>WAVELET</i> (PS-I-22).....	63
TABELA 9 - COMPARATIVO MSE, MAPE E MAE PARA A SÉRIE PS-I-22 <i>MULTI</i> <i>STEP H= 12</i>	65
TABELA 10 - MODELAGEM SARIMA JS-I-31/DESLIZAMENTO	67
TABELA 11 - MODELAGEM SARIMA JS-I-32/ASSENTAMENTO	67
TABELA 12 - DOIS MELHORES RESULTADOS PARA CADA FAMÍLIA <i>WAVELET</i> (JS-I-31/DESLIZAMENTO).....	68
TABELA 13 - DOIS MELHORES RESULTADOS PARA CADA FAMÍLIA <i>WAVELET</i> (JS-I-32/ASSENTAMENTO).....	68
TABELA 14 - COMPARATIVO MSE, MAPE E MAE PARA A SÉRIE JS-I-31/D <i>MULTI</i> <i>STEP H= 12</i>	71
TABELA 15 - COMPARATIVO MSE, MAPE E MAE PARA A SÉRIE JS-I-32/A <i>MULTI</i> <i>STEP H= 12</i>	71
TABELA 16 - MODELAGEM SARIMA EM-I-7-1.....	74
TABELA 17 - MODELAGEM SARIMA EM-I-9-1.....	74
TABELA 18 - DOIS MELHORES RESULTADOS PARA CADA FAMÍLIA <i>WAVELET</i> (EM-I-7-1).....	75
TABELA 19 - DOIS MELHORES RESULTADOS PARA CADA FAMÍLIA <i>WAVELET</i> (EM-I-9-1).....	75

TABELA 20 - COMPARATIVO MSE, MAPE E MAE PARA A SÉRIE EM-I-7-1 *MULTI*
STEP $H=12$ 78

TABELA 21 - COMPARATIVO MSE, MAPE E MAE PARA A SÉRIE EM-I-9-1 *MULTI*
STEP $H=12$ 78

LISTA DE SIGLAS

ARIMA: Autoregressive Integrated Moving Average
ARMA: Autoregressive Moving Average
CO: Pêndulo Direto
EM: Extensômetro
FAC: Função de Autocorrelação
FACP: Função de Autocorrelação Parcial
IC: Intervalo De Confiança
JS: Base de Alongômetro
MAE: Mean Absolute Error
MAPE: Mean Absolute Percent Error
MSE: Mean Squared Error
MSNM: Metros Sobre O Nível Do Mar
PS: Piezômetro
SARIMA: Seasonal ARIMA
SVM: Support Vector Machine
SVR: Support Vector Regression
SSVRWMN: Sarima Support Vector Regression Wavelet Múltiplos Núcleos

SUMÁRIO

1 INTRODUÇÃO	15
1.1 OBJETIVOS	17
1.1.1 Objetivo Geral	17
1.1.2 Objetivos Específicos	17
1.2 JUSTIFICATIVA	18
1.3 ESTRUTURA DO TRABALHO	20
2 REVISÃO DA LITERATURA	21
2.1 TEORIA <i>WAVELET</i>	21
2.1.1 Função <i>Wavelet</i>	21
2.1.2 Transformada <i>Wavelet</i>	23
2.2 MODELOS SARIMA	23
2.3 <i>SUPPORT VECTOR REGRESSION</i>	25
2.4 COMBINAÇÃO DE PREVISÕES	29
2.5 <i>BOOTSTRAP</i>	32
2.6 INTERVALOS DE CONFIANÇA	34
3 MATERIAIS E MÉTODOS	35
3.1 MATERIAIS	35
3.1.1 O Problema dos Deslocamentos	35
3.1.2 Pêndulo Direto CO-I-2/X	40
3.1.3 Piezômetro PS-I-22	41
3.1.4 Base de alongômetro JS-I-31/deslizamento e JS-I-32/assentamento	42
3.1.5 Extensômetros EM-I-7/1 e EM-I-9/1	43
3.2 MÉTODO HÍBRIDO SARIMA <i>SUPPORT VECTOR REGRESION WAVELET</i> DE MÚLTIPLOS NÚCLEOS - SSVRWMN	44
3.2.1 Modelagem via SARIMA	45
3.2.2 Decomposição <i>Wavelet</i> da Série Observada	46
3.2.3 Modelagem das Componentes <i>Wavelet</i> via SVR Múltiplos Núcleos	49
3.2.4 Combinação Linear das Bases <i>Wavelets</i> Previstas por SVRMN	51
3.2.5 Previsões Pontuais	52
3.2.6 Intervalo de Confiança	53
4 RESULTADOS E DISCUSSÃO	55

4.1.1 Pêndulo Direto.....	56
4.1.2 Piezômetro	62
4.1.3 Base de Alongâmetro	66
4.1.4 Extensômetros	73
5 CONCLUSÃO E CONSIDERAÇÕES FINAIS.....	80
REFERÊNCIAS.....	82

1 INTRODUÇÃO

Uma série temporal é um conjunto de observações correlacionadas sequencialmente no tempo, existente nas mais variadas áreas de aplicação, como por exemplo: engenharia, economia, biologia, ciências sociais, entre outras ciências. O foco na maioria das vezes é a necessidade de se prever realizações futuras de fenômenos de interesse. Técnicas estatísticas e o avanço tecnológico estão propiciando, cada vez mais, o uso de previsões que auxiliam os tomadores de decisão em análises e planejamento de necessidades operacionais futuras em áreas diversificadas. Pesquisadores vêm se empregando na obtenção de modelos estatísticos confiáveis e que apresentem boa precisão e, neste contexto, muitos métodos híbridos são apresentados (WALLIS, 2011). Morettin e Toloi (2006) e Ehlers (2009) ressaltam que, independentemente da metodologia utilizada na previsão, o objetivo é minimizar erros provenientes dos processos na obtenção de previsões (BOX *et al.* 2008).

No estudo de séries de tempo, três etapas são imprescindíveis: a análise, a modelagem e a previsão. Dentre as diversas técnicas usadas na análise, modelagem e previsão de séries temporais, é possível citar: a teoria *Wavelet*, a metodologia de Box e Jenkins, o método *Support Vector Regression* e a combinação de previsões. Maiores detalhes sobre estas aplicações são encontrados nos seguintes trabalhos: Haar (1911), Mallat (2009), Box *et al.* (2008), Vapnik (2005), Smola e Schölkopf (1998), Bates e Granger (1969) e Teixeira Jr. (2013).

A abordagem *Wavelet* para séries de tempo teve grande avanço com o trabalho de Daubechies (1988), que apresentou um conjunto de bases ortonormais de *Wavelet* suaves, passando a ser uma das principais referências para as atuais aplicações de *Wavelet*, conforme relata Cohen *et al.* (1992). Da Análise *Wavelet* (ou Teoria *Wavelet*) advêm importantes métodos auxiliares de pré-processamento que consistem, basicamente, em fazer a decomposição, filtragem ou alisamento dos dados temporais, antes de sua efetiva modelagem, conforme Aquino *et al.* (2009). É possível listar alguns trabalhos recentes que utilizam *Wavelet* no processo de previsão de séries temporais, tais como: Maheswaran e Khosa (2015); Seo *et al.* (2015); Zhu *et al.* (2014); Ortega e Khashanah (2014); Liu *et al.* (2013); Sang (2013); Teixeira Jr. *et al.* (2012); Kisi e Cimen (2011), entre outros.

A metodologia de Box e Jenkins (BOX *et al.* 2008) é a abordagem mais conhecida e utilizada no estudo de séries temporais e consiste em ajustar modelos autorregressivos integrados (AR) e de médias móveis (MA), sendo denominada de metodologia ARIMA. De acordo com Pankratz (2009), o modelo ARIMA é estabelecido a partir de três etapas: identificação da estrutura do modelo, estimação dos parâmetros e verificação do modelo ajustado. Tais modelos são recomendados para séries temporais provenientes de processos lineares conforme indicam Morettin e Toloi (2006) e Box *et al.* (2008). Vários trabalhos são encontrados na literatura onde se aplica a metodologia de Box e Jenkins, como por exemplo: Hassan (2014), Babu e Reddy (2014), Babai *et al.* (2013), Crespo *et al.* (2013), Alwee *et al.* (2013), Sujjaviriyasup e Pitiruek (2013), Zhu e Wei (2013), Faruk (2010), Areekul *et al.* (2010), Pai e Lin (2005), Zhang (2003), entre outros.

O método *Support Vector Regression* (SVR), apresentado em Vapnik (1995), é fundamentado pela técnica *Support Vector Machine* (SVM). Essa técnica vem alcançando bons resultados quando comparada com outras, tornando-se assim uma alternativa para resolver problemas de regressão não linear. Diversas pesquisas vêm sendo implementadas com a utilização dessa teoria, obtendo sempre bons resultados quando comparadas com outros métodos preditivos, como por exemplo: Yao *et al.* (2015), Altameem *et al.* (2015), Rodrigues *et al.* (2015), Piri *et al.* (2015), Chen *et al.* (2015), Lu (2014), Baydaroğlu e Koçak (2014), Kao *et al.* (2013), Hong (2011), He *et al.* (2008), entre outros.

A combinação de previsões de acordo com Clemen (1989) é uma metodologia atraente na obtenção de previsões, pois ao invés de escolher a melhor técnica, o problema passa a ser de quais técnicas podem ajudar na melhoria da acurácia. Conforme Teixeira Jr. (2013), as previsões pontuais são combinadas utilizando um mecanismo ponderador de forma a minimizar a variância dos resíduos combinados ou outra função residual. Bates e Granger (1969) propuseram um método que combina os resultados dos modelos de previsão mais eficientes, com a finalidade de agregar as características mais relevantes de cada um dos modelos utilizados em uma determinada situação. Em Wallis (2011), Mancuso e Werner (2013), são feitas revisões históricas, nas quais são mencionados muitos dos principais artigos sobre combinação de métodos preditivos individuais. Esses artigos atestam sua utilização e eficiência, além de mostrarem uma enorme diversidade de aplicações e abordagens.

Dados de séries temporais constituem grande parte dos dados armazenados em bancos de dados do mundo real, conforme relata Agrawal *et al.* (1993), sendo um campo de pesquisa e de aplicação vasto e de interesse para muitos setores da economia, tais como: indústria, energia (distribuição), engenharia (por exemplo, em barragens hidrelétricas), entre outros. Muitos dos profissionais destas áreas precisam tomar decisões em seus planejamentos de operações futuras, necessitando então de métodos que lhes propiciem previsões confiáveis.

A principal motivação deste trabalho é o desenvolvimento de um método para previsões de séries temporais que apresente vantagens preditivas quando comparado com métodos tradicionais e com outros métodos existentes na literatura para previsões de séries temporais provenientes da aferição de instrumentos de barragens.

Dentre os diversos fatores que se pode considerar em uma barragem de concreto, os movimentos entre blocos, e entre estes e suas fundações, surgem como um assunto de extremo interesse e análise. Neste trabalho foram realizadas previsões das séries temporais provenientes de aferições dos instrumentos extensômetros, piezômetros, pêndulo direto e base de alongâmetro localizados no bloco-chave (I10) situado no trecho I da barragem da Usina Hidrelétrica de Itaipu, os quais contribuem no monitoramento do comportamento do bloco quanto ao seu tombamento no sentido montante-jusante.

1.1 OBJETIVOS

1.1.1 Objetivo Geral

Propor um método de previsão de séries temporais que agregue à modelagem a captação de estruturas de autodependência lineares e não lineares, combinando a decomposição *Wavelet*, os modelos ARIMA/SARIMA, a modelagem via SVR e a técnica *Bootstrap* na estimação dos intervalos de confiança.

1.1.2 Objetivos Específicos

- Verificar empiricamente o efeito da decomposição *Wavelet* na previsão de séries temporais.
- Mostrar a eficiência da modelagem via *Wavelet* SVR.

- Utilizar o *Bootstrap* com o objetivo de estimar os intervalos de confiança.
- Realizar a previsão de séries temporais provenientes da aferição de instrumentos localizados no bloco I10 da barragem de Itaipu.
- Comparar os resultados alcançados através do método proposto com outros métodos de previsão tradicionais: SARIMA, SVR e o composto SARIMA-SVR.

1.2 JUSTIFICATIVA

Ao longo dos anos, diversos métodos preditivos vêm sendo propostos com o objetivo de se projetar séries temporais, com maior precisão. Na literatura, a combinação de métodos preditivos produz ganhos significativos de precisão na previsão de séries temporais, conforme pode ser visto em Teixeira Jr. *et al.* (2015), Mancuso e Werner (2013), para alguns casos específicos.

Conforme Wallis (2011), não se pode afirmar que existe uma combinação de métodos preditivos que seja considerada a melhor na projeção de séries temporais, constituindo-se, portanto, num campo de pesquisa aberto.

A decomposição *Wavelet*, aliada à combinação de previsores (SARIMA e SVR), se apresenta como um campo de pesquisa onde há espaço a ser explorado, como pode ser visto em Tan *et al.* (2010), Shi *et al.* (2012), Cheng e Hu (2012), Zhu *et al.* (2014) e Seo *et al.* (2015). A existência de aplicações reais em diferentes áreas de pesquisa, onde a linearidade e não linearidade temporal se apresentam, torna a busca de métodos de previsão de séries temporais eficientes uma área em expansão.

Deste modo, o estabelecimento de novos métodos que ofereçam ganhos na análise e previsão de séries temporais é de interesse tanto para o meio acadêmico quanto para o meio empresarial. Devido a isso, este trabalho propõe um método híbrido para fazer previsões de séries temporais.

Dos diversos métodos e aplicações de séries temporais existentes na literatura, todos se preocupam com a melhoria da precisão nas previsões (WALLIS, 2011), portanto, o presente trabalho se insere neste contexto e propõe uma abordagem híbrida de previsão de séries temporais, englobando a decomposição *Wavelet*, a modelagem através dos modelos ARIMA/SARIMA, a modelagem por *Support Vector Regression* (SVR), a combinação de previsões e a simulação das densidades preditivas para o cálculo dos intervalos de confiança via *Bootstrap*.

Basicamente, o método proposto contempla tanto sinais com estruturas de autodependência linear como não linear presentes em uma série temporal, e possui quatro etapas descritas a seguir, que podem ser observadas no fluxograma da Figura 1.

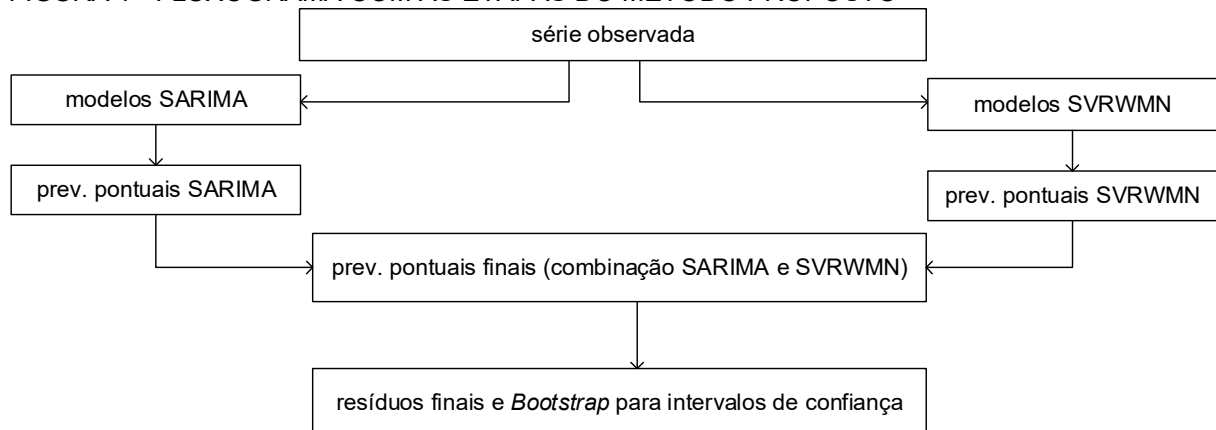
Etapa 1: Modelagem da série original, através de um modelo SARIMA, obtendo as previsões pontuais;

Etapa 2: Decomposição ortogonal (usando *Wavelet*) da série temporal observada, e modelagem das componentes *Wavelet* através de um modelo *Support Vector Regression* de Múltiplos Núcleos (SVRMN) e posterior combinação das previsões das componentes *Wavelet*, originando o modelo SVRWMN;

Etapa 3: Combinar as previsões dos modelos SARIMA e *Support Vector Regression Wavelet* de Múltiplos Núcleos (SVRWMN), obtidos nas etapas 1 e 2, obtendo as previsões híbridas pontuais da série temporal original;

Etapa 4: Tomar os resíduos da etapa 3 e utilizar a técnica *Bootstrap* para o cálculo do intervalo de confiança.

FIGURA 1 - FLUXOGRAMA COM AS ETAPAS DO MÉTODO PROPOSTO



FONTE: O autor (2015).

Vale salientar que na etapa 2 a previsão da série temporal decomposta por componentes *Wavelet* através da metodologia SVR Múltiplos Núcleos é um dos ineditismos apresentados neste trabalho, bem como a combinação do modelo SARIMA com o modelo SVRWMN na etapa 3. Detalhes dos métodos serão abordados no capítulo 3.

Com o propósito de avaliar o método proposto SSVRWMN, foi realizada a modelagem de séries temporais de natureza, complexidade e características de

comportamento diversificadas, que auxiliam na análise do deslocamento do bloco I10 da barragem da Usina Hidrelétrica de Itaipu. Para os casos abordados, o método proposto SSVRWMN gerou ganhos preditivos, quando comparado com os métodos individualizados presentes neste trabalho.

1.3 ESTRUTURA DO TRABALHO

Esta tese está dividida em cinco capítulos: (1) Introdução; (2) Revisão da Literatura; (3) Materiais e Métodos; (4) Resultados e Discussão; (5) Conclusão e Considerações Finais. No capítulo 2 encontram-se os conceitos das técnicas que integram o método, que são: decomposição Wavelet, modelos SARIMA, *Support Vector Regression*, combinação de Previsão e *Bootstrap*. No capítulo 3 está a descrição dos dados utilizados e detalhes do método proposto. Já o capítulo 4 traz os resultados das modelagens, através do método proposto para as séries provenientes das aferições dos instrumentos instalados no bloco-chave I10 da barragem da Usina Hidrelétrica de Itaipu onde é realizada uma discussão dos resultados. Enfim, o capítulo 5 apresenta a conclusão e sugestões de trabalhos futuros.

2 REVISÃO DA LITERATURA

Neste capítulo é feita uma breve revisão das técnicas que integram o método proposto, que são: a decomposição *Wavelet*, modelos SARIMA, *Support Vector Regression*, combinação de previsões e a técnica de amostragem *Bootstrap*.

2.1 TEORIA WAVELET

A primeira menção sobre *Wavelet* ocorreu em 1909, no trabalho de Haar (1910). Entretanto, o conceito *Wavelet* foi proposto pelo geofísico Morlet (1983). Um histórico sobre a origem da teoria *Wavelet* se encontra no artigo de Meyer (1993).

O grande avanço em aplicações aconteceu a partir de 1985 com os trabalhos de Mallat (1989) e Daubechies (1990).

Pode-se dizer que a função *Wavelet* é capaz de decompor ou representar uma série temporal originalmente descrita no domínio do tempo de tal forma que a série possa ser analisada em diferentes escalas de frequência e de tempo, (DAUBECHIES, 1992).

2.1.1 Função *Wavelet*

De acordo com Kubrusly (2011), um elemento $\omega(\cdot)$ em um *espaço de Hilbert* $(l^2, \langle \cdot; \cdot \rangle)$ onde $l^2 := \left\{ \{\xi_i\}_{i \in \mathbb{Z}} : \sum_{i \in \mathbb{Z}} |\xi_i|^2 < \infty \right\}$ é uma *função l^2 -Wavelet*, se a sequência $\left\{ \omega_{m,n}(\cdot) := 2^{\frac{m}{2}} \omega[2^m(\cdot) - n] \right\}_{(m,n) \in \mathbb{Z} \times \mathbb{Z}}$ de funções for uma base ortonormal de l^2 . Conforme Kubrusly e Levan (2006), o parâmetro m é chamado de escala e n , de parâmetro de translação.

Desta forma, uma função $y(\cdot) \in l^2$ admite sua expansão ortogonal por meio de uma série de Fourier, em termos de uma base ortonormal *Wavelet* $\{\omega_{m,n}(\cdot)\}_{(m,n) \in \mathbb{Z} \times \mathbb{Z}}$ para l^2 , definida na Equação (1).

$$y(\cdot) = \sum_{m \in \mathbb{Z}} \sum_{n \in \mathbb{Z}} \langle y(\cdot); \omega_{m,n}(\cdot) \rangle \omega_{m,n}(\cdot) \quad (1)$$

Conforme Kubrusly e Levan (2006), o subespaço fechado $W_m(\omega) := \left(\text{span} \{ \omega_{m,n}(\cdot) \}_{n \in \mathbb{Z}} \right)^\perp$ incluso em l^2 é chamado de subespaço de *detalhe*, na escala m . Segundo Daubechies (1988), para cada $m \in \mathbb{Z}$, a projeção ortogonal de $y(\cdot)$ sobre o subespaço de *detalhes* $W_m(\omega)$ de l^2 , é definida pela soma parcial na escala m , dada pela Equação (2).

$$y_{W_m(\omega)}(\cdot) := \sum_{n \in \mathbb{Z}} \langle y(\cdot); \omega_{m,n}(\cdot) \rangle \omega_{m,n}(\cdot) \quad (2)$$

De acordo com Teixeira Jr. *et al.* (2015), um elemento $\phi(\cdot)$ no espaço de *Hilbert* $(l^2, \langle \cdot; \cdot \rangle)$ é uma *função* l^2 -*Wavelet* *escala* se as funções $\phi_{m_0,n}(\cdot) := 2^{\frac{m_0}{2}} \phi(2^{m_0}(\cdot) - n)_{(m_0,n) \in \mathbb{Z} \times \mathbb{Z}}$ forem tais que, $\langle \phi_{l,i}; \phi_{j,k} \rangle = 0$, sempre que $l = j$ e $i \neq k$, e $\langle \phi_{l,i}; \phi_{j,k} \rangle \neq 0$, caso contrário.

Segundo Mallat (2009), o subespaço fechado $V_{m_0}(\phi) := \left(\text{span} \{ \phi_{m_0,n}(\cdot) \}_{n \in \mathbb{Z}} \right)^\perp$ de l^2 é chamado de subespaço de aproximação, na escala m_0 . Conforme Kubrusly e Levan (2006), a projeção ortogonal de $y(\cdot)$ sobre o subespaço de aproximação $V_{m_0}(\phi)$ é definida pela soma parcial, na escala m_0 , dada na Equação (3).

$$y_{V_{m_0}(\phi)}(\cdot) := \sum_{n \in \mathbb{Z}} \langle y(\cdot); \phi_{m_0,n}(\cdot) \rangle \phi_{m_0,n}(\cdot) \quad (3)$$

De acordo com Daubechies (1988), a projeção ortogonal $y_{V_{m_0}(\phi)}(\cdot)$ sobre o subespaço $V_{m_0}(\phi)$ pode ser referida como uma componente de aproximação *Wavelet* de uma função $y(\cdot)$ em $(l^2, \langle \cdot; \cdot \rangle)$, na escala m_0 .

Uma função $y(\cdot)$ em $(l^2, \langle \cdot; \cdot \rangle)$ pode ser interpretada como a soma de uma componente *Wavelet* de aproximação, na escala m_0 , e de infinitas componentes de detalhe na escala $\{m\}_{m=m_0}^{+\infty}$, conforme Equação (4).

$$y(\cdot) := y_{V_{m_0}(\phi)}(\cdot) + \sum_{m=m_0}^{+\infty} y_{W_m(\omega)}(\cdot) \quad (4)$$

2.1.2 Transformada *Wavelet*

Segundo Kubrusly (2011), uma transformada *Wavelet* sobre l^2 é definida por um produto interno entre uma função $y(\cdot)$ em $(l^2, \langle \cdot, \cdot \rangle)$ e uma função *Wavelet* $\omega_{m,n} \in W_m(\omega)$ ou uma função escala $\phi_{m,n} \in V_m(\phi)$, onde $(m, n) \in \mathbb{Z} \times \mathbb{Z}$.

De acordo com Morettin e Toloi (2006), as transformadas *Wavelet* podem ser agrupadas em dois conjuntos disjuntos: o dos coeficientes de detalhe, denotado por $\{d_{m,n}\}_{(m,n) \in \mathbb{Z} \times \mathbb{Z}}$, e o dos coeficientes de aproximação, denotado por $\{a_{m,n}\}_{(m,n) \in \mathbb{Z} \times \mathbb{Z}}$, onde os coeficientes de detalhe são definidos, respectivamente nas Equações (5) e (6).

$$d_{m,n} := \langle y(\cdot), \omega_{m,n}(\cdot) \rangle = \sum_{t \in \mathbb{Z}} y(t) \omega_{m,n}(t) \quad (5)$$

$$a_{m,n} := \langle y(\cdot), \phi_{m,n}(\cdot) \rangle = \sum_{t \in \mathbb{Z}} y(t) \phi_{m,n}(t) \quad (6)$$

Conforme Teixeira Jr. *et al.* (2015) e Kubrusly e Levan (2009) uma função $y(\cdot)$ em $(l^2, \langle \cdot, \cdot \rangle)$ é definida em termos de uma base ortonormal *Wavelet* como a soma de uma componente *Wavelet* de aproximação, na escala m_0 , e de infinitas componentes de detalhe na escala $\{m\}_{m=m_0}^{+\infty}$, dada genericamente pela Equação (7):

$$y(\cdot) := \sum_{n \in \mathbb{Z}} a_{m_0,n} \phi_{m_0,n}(\cdot) + \sum_{m=m_0}^{+\infty} \sum_{n \in \mathbb{Z}} d_{m,n} \omega_{m,n}(\cdot) \quad (7)$$

2.2 MODELOS SARIMA

Propostos por Box e Jenkins (1970), os modelos de Box e Jenkins têm o objetivo de identificar um sistema probabilístico plausível gerador de uma série temporal que exibe estacionariedade de segunda ordem (isto é, média e covariância constantes) e estrutura de autodependência linear (autocorrelação), utilizando apenas as informações nela contidas.

Sendo a série temporal denotada por $(y(t))_{t=1}^T$, que possui as duas propriedades enunciadas anteriormente, um modelo ARMA(p, q) é matematicamente representado pela Equação (8).

$$y(t) = \delta + \phi_1 y(t-1) + \phi_2 y(t-2) + \dots + \phi_p y(t-p) - \theta_1 a(t-1) - \theta_2 a(t-2) - \dots - \theta_q a(t-q) + a(t) \quad (8)$$

Onde o parâmetro p refere-se à ordem da parte autorregressiva e q , à ordem da parte de médias móveis, $\phi_i, \theta_j \in \mathbb{R}$, com $i=1, \dots, p$ e $j=1, \dots, q$, são os parâmetros do modelo dado na Equação (8) e δ , um intercepto complexo. Em outras palavras, tem-se que $(y(t))_{t=1}^T$ é explicado pelos seus valores defasados até p instantes e pelo ruído branco independentes e identicamente distribuídos (iid) e defasados q instantes.

Por outro lado, se a série temporal for não estacionária, esta deve ser diferenciada, para alcançar a estacionariedade de modo que pode ser representada por um modelo ARIMA(p, d, q), sendo d o grau de diferenciação. Um modelo ARMA(p, q) é, de fato, um modelo ARIMA($p, 0, q$).

Em termos práticos, ao se utilizar a modelagem ARIMA, dois princípios são considerados: parcimônia (que estabelece um modelo com o menor número de parâmetros possível); e ciclo iterativo (que consiste em uma estratégia de seleção de modelos), (MORETTIN e TOLOI, 2006).

No que concerne à identificação das ordens (p, d, q) iniciais, podem ser determinadas por meio da análise do perfil dos gráficos das funções de autocorrelação (FAC) e autocorrelação parcial (FACP), conforme Hamilton (1994).

Uma vez identificado um modelo plausível, passa-se ao estágio da estimação de seus parâmetros. Para tanto, é necessário utilizar métodos iterativos não lineares, em associação com o método da máxima verossimilhança, (MORETTIN e TOLOI, 2006) e (BOX *et al.* 2008).

Para a validação de um modelo estimado, testes de diagnósticos são utilizados (como, por exemplo, teste de Box-Pierce, Ljung-Box, Durbin-Watson, critério de informação AIC, BIC, periodograma acumulado, autocorrelação simples e parcial), (HAMILTON, 1994).

No caso da série temporal $(y(t))_{t=1}^T$ apresentar sazonalidade (evidenciada nos gráficos horizontais e da FAC e FACP) são agregados à modelagem ARIMA termos que capturam informações sazonais. Tal classe de modelos é referida por modelos SARIMA e está representada matematicamente pela Equação (9).

$$\phi(B)(1 - \Phi_1 B - \dots - \Phi_p B^{ps}) \nabla^d (1 - B^S)^D y(t) = \theta(B)(1 - \Theta_1 B - \dots - \Theta_q B^{qs}) a(t) \quad (9)$$

Onde: d é a ordem da diferença simples; D é a ordem da diferença sazonal (caso a sazonalidade presente não estacionariedade); S é o período sazonal; ϕ_k e $\theta_j \in \mathbb{R}$ são os coeficientes da parte não sazonal; Φ_m e $\Theta_n \in \mathbb{R}$ são os coeficientes da parte sazonal, (BOX *et al.* 2008).

2.3 SUPPORT VECTOR REGRESSION

As *Support Vector Machine* (SVMs) formam um sistema embasado pela teoria de aprendizado estatístico ou teoria VC (Vapnik-Chervonenkis), que vem sendo desenvolvido desde a década de 60 conforme relata Vapnik (1995). Foi apresentado pela primeira vez na *Annual Workshop on Computational Learning Theory*, COLT 1992 por Boser *et al.* (1992).

Inicialmente o SVM foi proposto para resolver problemas de classificação (SVC, *Support Vector Classification*), que propõe encontrar por meio da metodologia de aprendizagem um hiperplano separador de margem máxima. Tal hiperplano aceita a classificação de dados linearmente separáveis, seja no espaço de entrada ou em um espaço de dimensão maior. A classificação neste último espaço é permitida pelo uso das funções *Kernel*, (VAPNIK, 2005). O trabalho inicial com aplicações do SVM foi focado em reconhecimento óptico de caracteres (OCR, *Optical Character Recognition*), com fantásticos resultados conforme relata Schölkopf (1997).

O algoritmo SVM foi estendido para o caso de regressão, por Vapnik (1995), possibilitando estimar funções de valores reais. Surge então o chamado *Support Vector Regression Machine* (SVRM) ou simplesmente *Support Vector Regression* (SVR).

O modelo produzido pelo SVR depende apenas de um subconjunto de dados de formação e por sua função de custo utilizada para a construção do modelo, ignorando os dados de formação perto do modelo de previsão.

Atualmente, o SVR vem se mostrando como uma alternativa e uma técnica poderosa para resolver o problema de regressão não linear, como pode ser visto em vários trabalhos, como por exemplo: Zhu *et al.* (2015), Baydaroğlu e Koçak (2014), Anandhi e Chezian (2013), Hong (2011), entre outros.

As descrições a seguir sobre o SVR baseiam-se nos tutoriais de Smola e Schölkopf (1998) e Smola e Schölkopf (2004).

A ideia básica do SVR consiste em imaginar uma margem em volta do traçado da função de aproximação e encontrar uma função que tenha, no máximo, um erro previamente fixado sobre todos os exemplos, procurando-se assim obter uma margem que seja o mais estreito possível.

Seja uma amostra de dados de treinamento $(y(t), y(t+1))_{t=1}^{T-1} \subset X \times \mathbb{R}$, onde X indica o espaço de padrões de entrada (por exemplo $X = \mathbb{R}^{T-1}$), com $t = 1, 2, \dots, T-1$.

Na regressão ε -SV de Vapnik (1995), o objetivo é encontrar uma função $f(x(t))$, (sendo $x(t) = (y(t))_{t=1}^{T-1}$), que apresente no máximo um desvio ε dos alvos $d(t)$, (com $d(t) = (y(t+1))_{t=1}^{T-1}$), obtido para todos os dados de treinamento. Em outras palavras, o método não se preocupa com os erros, enquanto eles são menores que ε , mas não aceita qualquer desvio maior do que isso. Logo, descreve-se a função linear de aproximação da seguinte forma: $f(x) = \langle w, x \rangle + b$ com $w \in X$, $b \in \mathbb{R}$, onde $\langle \cdot, \cdot \rangle$ denota o produto interno em X . O objetivo é buscar uma função mais paralela ao domínio possível, que significa determinar valores pequenos para o vetor de pesos de w . Uma forma de garantir isso é minimizar a norma $(\|w\|^2 = \langle w, w \rangle)$ através do Problema (10), que pode ser considerado, como um problema de otimização convexa.

$$\begin{aligned} & \text{minimize} && \frac{1}{2} \|w\|^2 \\ & \text{sujeito a:} && \begin{cases} d(t) - \langle w, x(t) \rangle - b \leq \varepsilon \\ \langle w, x(t) \rangle + b - d(t) \leq \varepsilon \end{cases} \end{aligned} \quad (10)$$

Contudo, nem sempre é possível garantir a viabilidade do Problema (10) (VAPNIK, 2005), já que existem pontos que violam as restrições. No entanto pode-se introduzir variáveis de folga $\xi(t), \xi^*(t)$ para lidar com as restrições inviáveis do problema de otimização, ou seja, penalizando dados que se situem fora da margem.

Assim, chega-se à formulação mencionada em Vapnik (1995), com variáveis de folga, representada no Problema (11):


$$\begin{aligned}
& \text{minimize} && \frac{1}{2} \|w\|^2 + C \left(\sum_{t=1}^{T-1} \xi(t) + \xi^*(t) \right) \\
& \text{sujeito a :} && \begin{cases} d(t) - \langle w, x(t) \rangle - b \leq \varepsilon + \xi(t) \\ \langle w, x(t) \rangle + b - d(t) \leq \varepsilon + \xi^*(t) \\ \xi(t), \xi^*(t) \geq 0, \quad \forall t = 1, \dots, T-1 \end{cases}
\end{aligned} \tag{11}$$

Onde, $C > 0$ é a constante de regularização, ou seja, da penalização dos erros, pois pondera os termos da função de minimização.

Na Figura 2 observa-se que para valores entre $-\varepsilon$ e $+\varepsilon$ que formam a margem não existe penalização, ou seja, apenas os valores fora da margem são penalizados, neste caso, de forma linear. Isso corresponde a lidar com a chamada função de perda

dada por: $|\xi|_\varepsilon := \begin{cases} 0 & , \text{ se } |\xi| \leq \varepsilon \\ |\xi| - \varepsilon & , \text{ caso contrário} \end{cases}$.

FIGURA 2 - FUNÇÃO DE APROXIMAÇÃO (LADO ESQUERDO), FUNÇÃO DE PERDA (LADO DIREITO)



FONTE: Smola e Schölkopf, 1998.

Resolver o Problema (11) nem sempre é uma tarefa fácil devido às restrições de desigualdade, o modelo passa a ser dado no espaço dual, o que propicia a flexibilização do algoritmo.

Para a formulação dual, são introduzidos os multiplicadores de Lagrange $(\alpha(t), \alpha^*(t))$ não negativos conforme relata Vapnik (1995) e Smola e Schölkopf (1998). Logo o Problema (12), agora de maximização, na sua forma dual é dado por:

$$\begin{aligned}
& \text{Maximizar} \left(-\frac{1}{2} \right) \sum_{t,j=1}^{T-1} (\alpha(t) - \alpha^*(t)) (\alpha(j) - \alpha^*(j)) \langle x(t), x(j) \rangle + \\
& \quad - \varepsilon \sum_{i=1}^l (\alpha(t) + \alpha^*(t)) + d(t) \sum_{t=1}^{T-1} (\alpha(t) - \alpha^*(t)) \\
& \text{Sujeito a} \quad \sum_{t=1}^{T-1} (\alpha(t) - \alpha^*(t)) = 0 \\
& \quad \alpha(t), \alpha^*(t) \in [0, C], \quad \forall t = 1, \dots, T-1
\end{aligned} \tag{12}$$

$$f(x) = \sum_{t=1}^{T-1} (\alpha(t) - \alpha^*(t)) \langle x(t), x \rangle + b \tag{13}$$

Observa-se que a complexidade da função de aproximação não se sujeita à dimensionalidade do conjunto de treino, mas sim ao número de vetores de suporte. Neste ponto são introduzidas as condições de Karush–Kuhn–Tucker (KKT), (CORTES e VAPNIK, 1995) que são utilizadas no cálculo do parâmetro b .

Observa-se que somente para dados fora da margem é que os multiplicadores de Lagrange $(\alpha(t), \alpha^*(t))$ podem ser diferentes de zero, implicando que para valores dentro da margem, os multiplicadores $(\alpha(t), \alpha^*(t))$ são nulos e, portanto, são desconsiderados, anulando $x(t)$ na Equação (13). Desta forma, explica-se a esparsidade no desenvolvimento de w , pois só os dados que não são rejeitados é que fazem parte da otimização e são denominados de vetores-suporte.

A formulação dual do problema SVR fornece como alternativa trabalhar em um espaço de alta dimensionalidade. Assim, pode-se realizar um mapeamento não linear dos dados de entrada para um espaço de dimensão maior, onde a regressão linear torna-se possível. Para isso, utiliza-se a abordagem baseada em funções *Kernel* (VAPNIK, 1995), $K(x, x') := \langle \phi(x), \phi'(x') \rangle$, isto é, existe uma função K que recebe dois pontos (x, x') e calcula o seu produto escalar num espaço de características, cuja introdução no problema de otimização faz com que este passe a ser descrito conforme o Problema (14):

$$\begin{aligned}
& \text{Maximizar} -\frac{1}{2} \sum_{t,j=1}^{T-1} (\alpha(t) - \alpha^*(t)) (\alpha(j) - \alpha^*(j)) K(x(t), x(j)) + \\
& \quad - \varepsilon \sum_{t=1}^{T-1} (\alpha(t) + \alpha^*(t)) + d(t) \sum_{t=1}^{T-1} (\alpha(t) - \alpha^*(t)) \\
& \text{Sujeito a} \quad \sum_{t=1}^{T-1} (\alpha(t) - \alpha^*(t)) = 0 \\
& \quad \alpha(t), \alpha^*(t) \in [0, C], \quad \forall t = 1, \dots, T-1
\end{aligned} \tag{14}$$

E a função de aproximação da SVR não linear passa a ser dada pela Equação (15):

$$f(x) = \sum_{t=1}^{T-1} (\alpha(t) - \alpha^*(t)) K(x(t), x) + b \tag{15}$$

De acordo com Yu *et al.* (2006), as funções *Kernel* mais utilizadas são: *Kernel* linear: $K(x_i, x_j) := \langle x_i, x_j \rangle$, *Kernel* polinomial: $K(x_i, x_j) := [\gamma \langle x_i, x_j \rangle + c]^d$, *Kernel Sigmoidal*: $K(x_i, x_j) := \tanh[\gamma \langle x_i, x_j \rangle + c]$ e a função *Kernel* de base radial (*Kernel* gaussiano): $K(x_i, x_j) := \exp(-\gamma \|x_i - x_j\|^2)$.

Com a inclusão do *Kernel*, as SVM obtêm a característica descrita por Cortes e Vapnik (1995), que para assegurar que as funções de *Kernel* realizem o produto escalar no espaço de características, devem respeitar as condições de Mercer, (VAPNIK, 1995) e (SMOLA e SCHÖLKOPF, 2004).

Conforme relata Beltrami *et al.* (2010), os resultados obtidos pelo SVR dependem significativamente dos valores da constante de regularização C , margem ε , do tipo de função *Kernel* e seus respectivos parâmetros.

Neste trabalho, utilizou-se a tradução do termo *Kernel* que é núcleo, na descrição do método híbrido.

2.4 COMBINAÇÃO DE PREVISÕES

As primeiras obras que tratam da combinação de previsões foram desenvolvidas pelos pesquisadores Reid (1968) e Bates e Granger (1969), conforme relata Clemen (1989).

A combinação, de acordo com Clemen (1989), é um método atraente na obtenção de previsões, pois ao invés de escolher a melhor técnica, o problema passa a ser de quais técnicas podem ajudar na melhoria da acurácia, uma vez que a

performance da combinação geralmente é medida pela acurácia. Armstrong (2001) salienta que combinar previsões aumenta a aderência dos dados na medida em que os componentes da combinação contenham informações essenciais e independentes e recomenda que se for combinar previsões provenientes da mesma técnica é imprescindível que tais previsões contenham diferentes e relevantes informações.

É importante salientar que o termo “combinação de métodos preditivos individuais” pode ser utilizado em sentido amplo, referindo-se tanto à abordagem de combinação de previsões (MAKRIDAKIS e WINKLER, 1983), quanto à de combinação de densidades preditivas bayesianas, (FARIA e MUBWANDARIKWA, 2008). Neste trabalho, é utilizado apenas para se referir à combinação de previsões.

De acordo com Hollauer *et al.* (2009), a diversificação de previsões leva à diminuição do erro. Faria e Mubwandarikwa (2008) salientam que a previsão combinada é agregadora de informações oriundas de diferentes fontes (no caso, os métodos preditivos-base) sobre a flutuação estocástica da série temporal a ser modelada. Diversos autores propuseram formas de combinar previsões, como pode ser visto em: Granger e Ramanathan (1984), Gupta e Wilton (1987), Terui e Van Dijk (2002), Faria e Mubwandarikwa (2008), Teixeira Jr. (2009), Teixeira Jr. (2013), Billio *et al.* (2013), Sujjaviriyasup e Pitiruek (2013), He *et al.* (2014).

Em Wallis (2011) e Mancuso e Werner (2013) encontram-se revisões históricas, nas quais são referidos muitos dos principais artigos sobre combinação de métodos preditivos individuais, relatos que trazem mais de 42 anos de pesquisa na área, os quais atestam a utilização e eficiência, além de mostrarem uma variedade de aplicações e abordagens.

Faria e Mubwandarikwa (2008) relatam que existem duas possibilidades em se determinar um método preditivo gerador de previsões, que são:

- i) Escolher um método preditivo em $(\mu_m)_{m=1}^M$, baseado em alguma forma de seleção;
- ii) Escolher K métodos preditivos em $(\mu_m)_{m=1}^M$ e, em seguida, combiná-los (de forma linear ou não linear).

Onde, $(\mu_m)_{m=1}^M$ denota um conjunto com M métodos preditivos.

Em Makridakis e Winkler (1983), foi proposta a combinação linear de previsões oriundas de K métodos em $(\mu_m)_{m=1}^M$, onde $K \leq M$, utilizando pesos adaptativos

variantes no tempo. Os autores verificaram que as previsões combinadas foram mais precisas que as dos previsores individuais. Em Evans (2003), foi proposto o uso de uma constante aditiva na combinação linear de previsões. O autor mostrou em seus experimentos que a constante adaptativa acarretou ganhos preditivos.

Em Teixeira Jr. (2009), foram combinadas previsões de três métodos preditivos-base: um método de *amortecimento exponencial*, um modelo ARIMA e uma rede neural artificial. Os resultados estatísticos associados às previsões linearmente combinadas foram superiores aos das previsões dos previsores individuais.

De maneira geral, a ideia de combinar pode ser resumida nas duas etapas seguintes:

- i) Considerar Δ^K como um conjunto de todas as previsões (dentro e fora da amostra) oriundas de K métodos preditivos individuais escolhidos, pelo modelador, em $(\mu_m)_{m=1}^M$, onde $K \leq M$;
- ii) Obter o mapa $\hat{y}_{CL} : \begin{cases} \nabla^K \rightarrow \mathbb{R} \\ (\hat{y}_k(t))_{k=1}^K \in \nabla^K \rightarrow \hat{y}_{CL}(t) \in \mathbb{R} \end{cases}$ de combinação de previsões (genérico) que transforma um vetor $(\hat{y}_k(t))_{k=1}^K \in \nabla^K$ de previsões em uma previsão combinada $\hat{y}_{CL}(t) = \sum_{k=1}^K \rho_k \times \hat{y}_k(t) + \alpha$, para todo $t=1, \dots, T+h$.

Onde $h \in \mathbb{N}$ é o horizonte de previsão, $\hat{y}_{CL}(t)$ é a previsão linearmente combinada; $\hat{y}_k(t)$, a previsão do k -ésimo método-base; ρ_k , o peso adaptativo associado linearmente à previsão $\hat{y}_k(t)$; α e, constante adaptativa aditiva.

Teixeira Jr. (2013) utilizou programação matemática para calcular os coeficientes da combinação linear, otimizando um problema de programação não linear, onde a função objetivo era constituída pela soma dos erros de previsão ao quadrado.

Segundo Faria e Mubwandarikwa (2008), é comum a imposição das restrições

$\sum_{k=1}^K \rho_k = 1$ e $\rho_k \geq 0$ sobre os valores que os pesos adaptativos $(\rho_k)_{k=1}^K$ podem assumir,

a fim de preservar a sua interpretabilidade probabilística.

Conforme Teixeira Jr. (2013), as médias simples, ponderada ou harmônica, também podem ser utilizadas na combinação de previsões.

2.5 BOOTSTRAP

Introduzido por Efron (1979), o método *Bootstrap* é um procedimento estatístico não paramétrico cuja ideia principal é a reamostragem com reposição dos dados originais a fim de criar novos conjuntos de dados, que permitem estimar uma medida de interesse. O método *Bootstrap* é útil quando nenhum modelo probabilístico é aplicado ao conjunto de dados sob análise e/ou quando a quantidade de dados não é suficiente para usar o Teorema Central do Limite, (DAVISON e HINKLEY, 1997).

Considere $Y = (y(1), y(2), \dots, y(t))$ uma amostra aleatória de uma distribuição F desconhecida e $\hat{\theta} = s(Y)$ o estimador de um parâmetro θ dessa distribuição. O método *Bootstrap* gera um número B de amostras de mesmo tamanho, da amostra original, ou seja, $y^1(t), y^2(t), \dots, y^B(t)$. Essas amostras são denominadas amostras *Bootstrap* e são obtidas com reposição da amostra original Y . As B amostras *Bootstrap* são amostras independentes da distribuição empírica \hat{F} , que permite calcular o estimador *Bootstrap* do parâmetro de interesse, para cada uma das amostras, $\hat{\theta}^b = s(y^b(t))$ com $b = 1, 2, \dots, B$, (como por exemplo: média, erro padrão). De acordo com Efron e Tibshirani (1994), o conjunto B das amostras *Bootstrap* é utilizado para a estimação da verdadeira distribuição de probabilidade desconhecida, bem como intervalos de confiança.

O erro padrão do estimador *Bootstrap* pode ser obtido através da Equação (16).

$$\widehat{se}_{boot}(\hat{\theta}) = \left[\frac{1}{B-1} \sum_{b=1}^B \left(\hat{\theta}^b - \frac{1}{B} \sum_{b=1}^B \hat{\theta}^b \right)^2 \right]^{1/2} \quad (16)$$

Conforme Montgomery e Runger (2003), a definição do número B de amostras *Bootstrap* pode ser alcançada com a observação da variação do desvio padrão do estimador *Bootstrap*. Uma pequena variabilidade ou estabilidade desse valor indica o valor de B mais apropriado. Tibshirani (1996) gera entre 20 e 200 amostras *Bootstrap* em suas aplicações.

Tibshirani (1996) sugere, no contexto das regressões, dois tipos de amostragens *Bootstrap* que permitem determinar o intervalo de confiança: *Bootstrap pairs* e *Bootstrap residual*.

O *Bootstrap pairs* considera o conjunto de dados originais que são amostrados e substituídos no conjunto original, cada um deles com a mesma probabilidade de ser selecionado.

Já o *Bootstrap residual*, por sua vez, exige um modelo de regressão ajustado sobre o conjunto original de dados e o cálculo dos resíduos. Desta forma, os resíduos são reamostrados e novas séries são obtidas.

Neste trabalho é considerada a técnica *Bootstrap residual* na obtenção do intervalo de confiança. Segue um resumo do algoritmo do *Bootstrap residual*, (TIBSHIRANI, 1996).

Seja a série temporal $(y(t))_{t=1}^T$, com $t = 1, 2, \dots, T', T'+1, \dots, T$ valores da amostra original, o algoritmo é dado pelos seguintes passos:

- i) Obter o modelo ajustado $(\hat{y}(t))_{t=T'}^T$, referente aos dados originais $(y(t))_{t=1}^T$ onde T' indica os graus de liberdade não considerados;
- ii) Determinar os resíduos do modelo ajustado, $r = (y(t))_{t=T'}^T - (\hat{y}(t))_{t=T'}^T$;
- iii) Gerar B amostras *Bootstrap*, cada uma com tamanho $T - T'$ que serão obtidas com a reamostragem dos resíduos, obtendo $(r^b(t))_{t=T'}^T$, que são as B amostras *Bootstrap*;
- iv) Criar novas séries sintéticas, $(y^b(t))_{t=T'}^T = (\hat{y}(t) + r^b(t))_{t=T'}^T$;
- v) Para cada série sintética, obter o modelo ajustado $(\hat{y}^b(t))_{t=T'}^{T+h}$, $h \in \mathbb{N}$ e indicar os valores a serem previstos fora da amostra de treino.
- vi) Estimar o erro padrão do t -ésimo valor predito usando

$$\left[\frac{1}{B-1} \sum_{b=1}^B (\hat{y}^b(t) - \bar{\hat{y}}^b(t))^2 \right]^{1/2}, \text{ onde } \bar{\hat{y}}^b(t) = \frac{1}{B} \sum_{b=1}^B \hat{y}^b(t).$$

Para mais detalhes sobre *Bootstrap*, pode-se consultar os trabalhos de Efron e Tibshirani (1994) e Davison e Hinkley (1997).

2.6 INTERVALOS DE CONFIANÇA

Os intervalos de confiança são usados para estimar os parâmetros do modelo de regressão, (PAN e POLITIS, 2014). Com o intuito de adicionar informações de incerteza relacionadas com as estimativas pontuais decorrentes do método foram construídos intervalos de confiança (IC).

Considere os padrões $(y(t), \mathbf{x}(t))_{t=1}^T$ e o modelo de regressão proposto como sendo $y(\mathbf{x}) = f(\mathbf{x}, \mathbf{w}) + e(\mathbf{x})$, onde $y(\mathbf{x})$ são os alvos, \mathbf{w} são os parâmetros verdadeiros do modelo desconhecido $f(\mathbf{x}, \mathbf{w})$ e $e(\mathbf{x})$ o ruído (variável aleatória) com média zero. Sejam $\hat{\mathbf{w}}$ os estimadores de \mathbf{w} e $g(\mathbf{x}, \hat{\mathbf{w}})$ a aproximação de $f(\mathbf{x}, \mathbf{w})$, onde $g(\mathbf{x}, \hat{\mathbf{w}})$ pode ser interpretada como a média dos alvos y dada a entrada \mathbf{x} .

De acordo com Heskes (1997), para problemas de regressão a acurácia da estimativa da regressão verdadeira conduz à construção do intervalo de confiança. E segundo Khosravi *et al.* (2014) a incerteza do modelo de regressão ajustado é dada pela variância $\sigma_g^2(x)$ associada à aproximação $g(\mathbf{x}, \hat{\mathbf{w}})$ de $f(\mathbf{x}, \mathbf{w})$.

Khosravi *et al.* (2014), trabalharam com o *Bootstrap* e redes neurais, e sugeriram um intervalo de confiança expresso na Equação (17).

$$m(\mathbf{x}) - t_{1-\frac{\alpha}{2}, gl} \sigma_g(\mathbf{x}) \leq f(\mathbf{x}, \mathbf{w}) \leq m(\mathbf{x}) + t_{1-\frac{\alpha}{2}, gl} \sigma_g(\mathbf{x}) \quad (17)$$

Onde $t_{1-\frac{\alpha}{2}, gl}$ provêm da distribuição t de *Student* com nível de significância α , gl é o

número de graus de liberdade, definidos como sendo diferença entre o número de amostras de treinamento e o número de parâmetros do modelo e

$$m(\mathbf{x}_i) = \frac{1}{B} \sum_{b=1}^B g(\mathbf{x}_i, \hat{\mathbf{w}}^b).$$

De acordo com Haykin (2009), *Support Vector Machines* é uma categoria de redes neurais, com alterações na realimentação das camadas. Desta forma, neste trabalho foi utilizado o intervalo de confiança como descrito na Equação 17.

3 MATERIAIS E MÉTODOS

Neste capítulo são descritos os materiais utilizados, assim como o método híbrido proposto para previsão de séries temporais reais de dados de instrumentação geotécnica-estrutural da barragem da Usina Hidrelétrica de Itaipu, instaladas no bloco principal do trecho I.

Desta forma, inicia-se este capítulo com a apresentação das séries temporais da instrumentação de Itaipu a serem modeladas. Em seguida, cada etapa do método híbrido é definida, a saber: modelagem via modelos SARIMA; decomposição ortogonal *Wavelet*; modelagem via *Support Vector Regression* Múltiplos Núcleos; combinação de previsões; geração de cenários por *Bootstrap* e a determinação dos intervalos de confiança.

3.1 MATERIAIS

Nesta seção encontram-se as informações concernentes ao problema em análise, ou seja, as séries temporais provenientes dos instrumentos que auxiliam na análise do comportamento estrutural de um bloco da barragem de contrafortes. Sendo essas séries de tempo projetadas via método proposto.

3.1.1 O Problema dos Deslocamentos

A Itaipu Binacional, uma das maiores usinas hidrelétricas do mundo, está localizada no rio Paraná a 14km a montante da ponte internacional que liga a cidade de Foz do Iguaçu, no Brasil, à Ciudad del Este, no Paraguai, (ITAIPU: USINA HIDRELÉTRICA, 2009).

A barragem principal de Itaipu é de concreto, do tipo gravidade aliviada, sendo composta por 20 blocos, cada um dotado de uma unidade geradora. No total são 2792 instrumentos instalados no concreto e na fundação, fornecendo dados temporais que auxiliam na análise do comportamento dos blocos e, por consequência, da barragem como um todo. Alguns blocos são designados blocos-chave (como é o caso do Bloco I10, objeto de nosso estudo), os quais são dotados de maior quantidade de instrumentos.

Os blocos estão sujeitos, principalmente à ação do nível do lago devido à maior força que recebem da água no sentido montante-jusante, ou seja, no sentido do leito do rio. Esse volume de água também exerce, nas partes inferiores dos blocos, uma pressão (denominada de subpressão) que cria um efeito contrário ao que a sua própria massa exerce sobre a fundação, e das variações de temperatura, como no caso do verão em que ocorrem dilatações no concreto que provocam uma tendência de deformação do bloco para a direção montante, que por sua vez pode fazer com que aumentem as tensões de compressão no pé de montante dos blocos. No inverno o concreto se contrai, e provoca uma tendência de deformação do bloco a jusante. Pode-se então identificar um comportamento cíclico da estrutura, intimamente condicionado às condições ambientais da região, (OSAKO, 2002).

As barragens são obras que requerem atenção às diversas condições de segurança estrutural e operacional, a fim de evitar eventuais consequências danosas em suas estruturas ou até mesmo ao meio ambiente. A identificação de problemas e a execução de reparos diminuem o fator de risco, não obstante, tais estudos requerem muita atenção para a determinação de soluções adequadas.

As barragens de concreto de usinas hidrelétricas são, em geral, monitoradas com o auxílio de instrumentos que realizam aferições de diferentes tipos de movimentos dos blocos que compõem a sua estrutura (ITAIPU: USINA HIDRELÉTRICA, 2009).

Os dados aferidos ao longo do tempo podem ser do ponto de vista estatístico interpretados como séries temporais estocásticas que exibem estruturas de autodependência (visto que o valor de leitura corrente de um instrumento é afetado pelos valores passados). Com efeito, estas são tais que obedecem a um determinado regime estocástico de comportamento, o qual pode ser mapeado, de forma aproximada, por meio de um método preditivo, com a finalidade de se produzir previsões.

Uma vez que tais obras demandam muita atenção devido às diversas condições de segurança estrutural e operacional, o objetivo principal é minimizar as chances de consequências catastróficas em suas estruturas, ao meio ambiente ou às vidas humanas; além de custos financeiros exacerbados. Para tanto, a identificação prévia de problemas em sua estrutura de concreto, demanda que a equipe técnica responsável disponha de previsões acuradas dos valores futuros dos instrumentos nela instalados.

Dentre os diversos fatores considerados em uma barragem de concreto os movimentos entre blocos e entre estes e suas fundações surgem como um assunto de extremo interesse e análise. Basicamente os problemas de movimento em uma barragem são os seguintes: problemas de deformação como recalque, tombamento e deslizamento; problemas de infiltrações, devido à percolação de água dentro dela ou na fundação; excesso da pressão hidrostática como subpressões; problemas de resistência ao cisalhamento, como o de escorregamento de barragens e de taludes; problemas de galgamento, que geram forças não avaliadas em uma barragem.

Neste estudo são realizadas previsões das séries temporais de instrumentos pertencentes ao bloco-chave (I10) situado no trecho I da barragem da Usina Hidrelétrica de Itaipu, que contribuem no monitoramento do comportamento do bloco quanto ao seu tombamento no sentido montante-jusante. O bloco I10 é denominado de bloco-chave, por possuir um maior número de instrumentos instalados e tem sua localização na barragem de ligação esquerda, entre a estrutura de desvio e a barragem de enrocamento. Na Figura 3, a seta de cor preta indica a localização do trecho I.

FIGURA 3 - LOCALIZAÇÃO DO TRECHO I




FONTE: <https://www.itaipu.gov.br/> (2015).

Vale salientar que o estudo é sobre o comportamento do bloco com o seu tombamento, ou seja, foram realizadas previsões através do método proposto das séries temporais provenientes das aferições de instrumentos pré-selecionados que contribuem no monitoramento do tombamento do bloco I10. Sendo que o principal objetivo é mostrar a eficiência do método proposto para a previsão de séries temporais de instrumentos de barragens que apresentem diferentes características.

De acordo com Osako (2002), no mecanismo de tombamento, a barragem tende a girar em torno do ponto P' , entretanto, antes de ocorrer, são desenvolvidos esforços de tração e aumento de subpressão a montante, aumento de compressão a jusante e finalmente ruptura por deslizamento, conforme Figura 4.

FIGURA 4 - MOVIMENTO DE TOMBAMENTO




FONTE: Adaptado de Villwock (2009)

O tombamento é um movimento quase que total da estrutura e por esse motivo praticamente todos os instrumentos instalados são afetados quando essa anomalia ocorre ou tende a ocorrer. Por esse motivo, as informações futuras, dadas pelas previsões obtidas pelo método proposto, se tornam valiosas no auxílio às tomadas de decisões.

Os instrumentos foram selecionados com base em relato dos engenheiros responsáveis pela análise dos dados de instrumentação. Os instrumentos foram separados em duas categorias. Os instalados na fundação e os instalados na estrutura de concreto. Tais equipamentos estão destacados na Figura 5.

FIGURA 5 - LOCALIZAÇÃO DOS INSTRUMENTOS NO BLOCO I10



FONTE: <https://www.itaipu.gov.br/> (2015).

Os instrumentos que monitoram a fundação são os extensômetros e os piezômetros. Os extensômetros medem as deformações do maciço rochoso, ou seja, medem os deslocamentos e deformações que ocorrem entre pontos no maciço da fundação. Os piezômetros medem a subpressão, ou seja, aferem a pressão dos poros, a subpressão hidráulica em juntas ou contatos escolhidos no maciço rochoso ou no contato barragem-fundação. Para aplicação do método híbrido proposto foram selecionados dois extensômetros, um instalado na direção montante denominado de EM-I-7/1 e outro instalado a jusante EM-I-9/1. Também foi selecionado um piezômetro

denominado PS-I-22, instalado a montante. Já os instrumentos instalados na estrutura são as bases de alongâmetro e o pêndulo direto. As bases de alongâmetro são responsáveis pela aferição dos deslocamentos relativos entre os blocos. O pêndulo mede os deslocamentos da barragem, ou seja, mede os deslocamentos na direção jusante-montante e perpendicular ao fluxo do rio. Para a aplicação do método foram selecionadas duas bases de alongâmetro que são a base de alongâmetro JS-I-31/deslizamento e a base de alongâmetro JS-I-32/assentamento e um pêndulo direto representado por CO-I-2.

Cada instrumento selecionado está localizado estrategicamente no bloco-chave I10, sendo um total de seis instrumentos selecionados. Segue um relato sobre cada um dos seis instrumentos com suas características e apresentação de seu papel na análise. Vale frisar que a análise simultânea das aferições destes equipamentos auxilia no estudo do tombamento.


As aferições destes seis equipamentos forneceram as séries temporais que são objeto do experimento.

3.1.2 Pêndulo Direto CO-I-2/X

O pêndulo direto é um instrumento fixo à crista da barragem indo até o contato concreto-rocha, ou seja, é instalado na estrutura e é responsável em monitorar os deslocamentos da crista da barragem em relação ao ponto considerado fixo na fundação. Do pêndulo direto se obtêm duas aferições, uma no sentido montante-jusante (CO-I-2/X) e outra no sentido margem direita-esquerda (CO-I-2/Y). Nesta aplicação de análise de tombamento será considerada a série CO-I-2/X, que apresenta os deslocamentos horizontais da crista da barragem no sentido montante-jusante.

Para a série temporal proveniente da aferição do instrumento pêndulo direto CO-I-2/X, os valores são dados em milímetros e ela pode ser visualizada na Figura 6.

FIGURA 6 - SÉRIE TEMPORAL CO-I-2/X PERÍODO 1994 A 2014



FONTE: O autor (2015).


3.1.3 Piezômetro PS-I-22

O piezômetro é um instrumento instalado na fundação, sendo responsável pela aferição da subpressão atuante no local onde está instalado, ou seja, suas aferições medem as subpressões na fundação.

Conforme Osako (2002), os maiores desastres de barragens de gravidade ocorreram por resistência inadequada ao movimento horizontal, isto é, ruptura por cisalhamento na fundação. Por isso os efeitos da subpressão devem ser reconhecidos e estudados criteriosamente. Na fundação de uma barragem de concreto, a subpressão atua no sentido ascendente, ou seja, de baixo para cima, reduzindo o peso efetivo da estrutura e consequentemente a resistência ao cisalhamento dos planos potenciais de deslizamento existentes no maciço rochoso.

Foi considerado para a análise do tombamento o piezômetro PS-I-22, localizado a jusante no contato concreto-rocha no bloco I10. Os valores da série temporal proveniente das aferições do instrumento PS-I-22 são dados em metros sobre o nível do mar (MSNM) e ela pode ser visualizada na Figura 7.

FIGURA 7 - SÉRIE TEMPORAL PS-I-22 PERÍODO 1994 A 2014



FONTE: O autor (2015).

3.1.4 Base de alongâmetro JS-I-31/deslizamento e JS-I-32/assentamento


As bases de alongâmetro são instrumentos instalados na estrutura sendo responsáveis pela aferição dos deslocamentos relativos em juntas entre os blocos, ou seja, suas aferições medem os deslocamentos horizontais e verticais entre juntas.

Na verificação das deformações oriundas do movimento dos deslocamentos relativos, são feitas duas leituras em cada base de alongâmetro: uma das medidas corresponde à abertura ou fechamento das juntas, ao passo que a outra medida indica o deslizamento entre os blocos. O deslizamento, por sua vez, pode ser interpretado de duas formas, conforme as bases de alongâmetro estejam instaladas na parede ou no piso das galerias da estrutura. Quando no piso, o deslizamento indica um movimento relativo no sentido montante-jusante (JS-I-31/deslizamento). Quando na parede (JS-I-32/assentamento), corresponde a um recalque relativo entre os blocos, mais detalhes podem ser vistos nos trabalhos Matos (2002), Osako (2002) e Buzzi (2007).

Nesta análise foram selecionados dois instrumentos base de alongâmetro. Um instalado no piso das galerias da estrutura e outro na parede. A base de alongâmetro JS-I-31/deslizamento está instalada no piso entre os blocos I10 e I11, sendo suas

aferições referentes aos deslizamentos no sentido montante-jusante. A base de alongâmetro JS-I-32/assentamento está instalada na parede entre os blocos I10 e I11, sendo suas aferições referentes aos movimentos de recalque entre os blocos, ou seja, medem as deformações verticais. O instrumento-base de alongâmetro produz seus valores em milésimos de milímetros. As séries podem ser visualizadas na Figura 8.

FIGURA 8 - SÉRIE TEMPORAL JS-I-31/DESLIZ E JS-I-32/ASENTAMENTO PERÍODO 1994 A 2014



FONTE: O autor (2015).

3.1.5 Extensômetros EM-I-7/1 e EM-I-9/1


Os extensômetros são instrumentos instalados na fundação e são responsáveis pela aferição das deformações da fundação com relação ao ponto de ancoragem de sua haste. Este tipo de instrumento é considerado um dos mais importantes, pois é responsável pelas medições de recalques (deslocamentos verticais), que consistem em uma das observações mais importantes na supervisão do comportamento da estrutura da barragem.

Os dois extensômetros selecionados EM-I-7/1 e EM-I-9/1 estão localizados em maior profundidade na fundação: o extensômetro EM-I-7/1 se encontra a montante do

bloco I10 enquanto o extensômetro EM-I-9/1 se encontra a jusante do bloco I10. O instrumento extensômetro produz seus valores em milímetros.

As séries provenientes das aferições dos instrumentos extensômetros EM-I-7/1 e EM-I-9/1 podem ser visualizadas na Figura 9.

FIGURA 9 - SÉRIE TEMPORAL EM-I-7/1 E EM-I-9/1 PERÍODO 1994 A 2014



FONTE: O autor (2015).

3.2 MÉTODO HÍBRIDO SARIMA SUPPORT VECTOR REGRESION WAVELET DE MÚLTIPLOS NÚCLEOS - SSVRWMN

Em aplicações reais é de interesse do tomador de decisões, no contexto de modelagem de séries temporais, identificar estruturas de modelos lineares e não lineares plausíveis a um conjunto de dados e com um poder preditivo satisfatório. Assim, um método híbrido, com ambas as capacidades, tende a gerar previsões mais precisas, (ZHANG, 2003). De acordo com Faria e Mubwandarikwa (2008), previsões oriundas de combinações de métodos preditivos individuais são, de fato, agregadoras de informações (lineares e não lineares) advindas de diferentes fontes (modelos). Na literatura, encontram-se diversos trabalhos que objetivam capturar estruturas de modelos lineares e não lineares utilizando diversas abordagens e métodos, tais como: Tseng *et al.* (2002), Terui e Van Dijk (2002), Zhang (2003), Pai e Lin (2005), Aladag *et al.* (2009), Khashei e Bijari (2010), Khashei e Bijari (2011), Zheng e Zhong (2011),

Alwee *et al.* (2013), Alwee *et al.* (2013), Zhu e Wei (2013), Zhu *et al.* (2014), Babu e Reddy (2014), Mohammadi *et al.* (2015), entre outros.

Fundamentalmente, o método híbrido proposto considera o conceito mostrado em Zhang (2003), em que uma série temporal $(y(t))_{t=1}^T$ é constituída por uma componente linear e uma componente não linear apresentada na Equação (18).

$$(y(t))_{t=1}^T = (L(t))_{t=1}^T + (N(t))_{t=1}^T \quad (18)$$

Onde: $(L(t))_{t=1}^T$ denota a componente linear e $(N(t))_{t=1}^T$ a componente não linear da série temporal $(y(t))_{t=1}^T$.

Consequentemente, métodos de previsão linear e não linear podem ser usados na modelagem de $(L(t))_{t=1}^T$ e $(N(t))_{t=1}^T$, respectivamente, a fim de gerar as sequências $(\hat{L}(t))_{t=1}^{T+h}$ e $(\hat{N}(t))_{t=1}^{T+h}$ que consistem em previsões dentro e fora da amostra. Note que h representa o horizonte de previsão e $t = 1, 2, \dots, T$ são os instantes de tempo utilizados no ajuste do modelo (dados de treinamento) e $t = T + h$ os tempos utilizados para verificar a eficácia do modelo, ou seja, amostra teste, com $h \in \mathbb{N}$.

Nas seções 3.2.1 a 3.2.6 são apresentadas as etapas do método híbrido proposto. O método considera uma série temporal $(y(t))_{t=1}^T$ que será projetada pela média das previsões obtidas por um modelador linear e um não linear.

3.2.1 Modelagem via SARIMA

Os modelos SARIMA ou modelos de Box-Jenkins (BOX e JENKINS, 1970) têm como característica a busca de modelos adequados que sejam parcimoniosos. Estes modelos são os mais conhecidos para análise de séries temporais no domínio do tempo, em que exista sazonalidade. Uma de suas suposições é a respeito da linearidade da série de dados, tanto em relação à média quanto em relação à variância, conforme Box *et al.* (2008). Apesar das estimativas dos parâmetros serem razoavelmente robustas, a não linearidade da média continua sendo uma falha de suposição. Porém, uma das possibilidades de se trabalhar com esta falha de suposição é o uso de modelos que captem estruturas de dependência não linear.

O modelo híbrido proposto requer a previsão de uma componente linear, sendo então consideradas para este fim as previsões obtidas pelo modelo SARIMA, que visam capturar as estruturas de autodependência linear, considerando o efeito sazonal. Caso não apresente sazonalidade será considerado o modelo ARIMA.

Sendo a série temporal $(y(t))_{t=1}^T$, que é modelada via SARIMA, obtém-se as previsões $(\hat{y}(t))_{t=T'}^T$, com $t = 1, 2, \dots, T', T'+1, \dots, T$ que compreendem os dados de treinamento (T' são os graus de liberdade não considerados pelo modelo SARIMA, com $T' < T$ e $(\hat{y}(t))_{t=T'+h}^H$ com $h = 1, 2, \dots, H$ que é o horizonte de previsão (dados de teste)).

As estimativas dos parâmetros do modelo SARIMA são determinadas por Máxima Verossimilhança usando o algoritmo de Marquardt (MARQUARDT, 1963) implementado no software *EViews* 8. A definição das ordens dos modelos, inicialmente, ocorre com a análise dos gráficos das funções de autocorrelação FAC, autocorrelação parcial FACP, resíduos e testes com diversas opções de ordens p, d e q .

3.2.2 Decomposição *Wavelet* da Série Observada

Antes da modelagem, via um modelador não linear, neste caso o SVR, faz-se a decomposição *Wavelet*, que detecta o comportamento de uma série temporal em altas e baixas frequências. Isto tem o intuito de reduzir possíveis ruídos existentes na série original. Sendo, neste caso, considerada apropriada pois, conforme Mallat (2009), cada componente *Wavelet* (CW) está associada a um parâmetro de escalonamento fixo, o que implica que a frequência do espectro de cada uma é constante (o que significa que a CW sempre apresenta padrão de comportamento mais regular para fins de modelagem).

Nesta etapa é realizada a decomposição ortogonal *Wavelet* de nível r na série $(y(t))_{t=1}^T$, gerando $r+1$ CWs, (DONOHO e JOHNSTONE, 1994).

Conforme Teixeira Jr. *et al.* (2015), a decomposição *Wavelet* de nível r de uma série temporal $(y(t))_{t=1}^T$ em relação a uma determinada base ortonormal *Wavelet* é representada pela Equação (19) :

$$(y(t))_{t=1}^T = (\tilde{y}_{A_{m_0}}(t))_{t=1}^T + \sum_{m=m_0}^{m_0+(r-1)} (\tilde{y}_{D_m}(t))_{t=1}^T + (\varepsilon(t))_{t=1}^T \quad (19)$$

Onde: m_0 representa o nível do parâmetro (inicial); $\varepsilon(t)$ é o erro da aproximação de

$y(t)$; $\tilde{y}_{A_{m_0}}(t) := \sum_{n=0}^{2M-m_0-1} a_{m_0,n} \varphi_{m_0,n}(t)$ e $\tilde{y}_{D_m}(t) := \sum_{n=0}^{2^{(M-m_0)}-1} d_{m,n} \omega_{m,n}(t)$ são, respectivamente, as

CWs de aproximação e de detalhe, conforme visto na seção 2.1.

Na prática, é usual que o parâmetro m_0 tome valor igual ao nível de decomposição r (isto é, truncamento na r -ésima componentes de aproximação), (TEIXEIRA JR *et al.*, 2013).

Independentemente do nível r de decomposição *Wavelet*, observa-se empiricamente que $\varepsilon(t)$ é, em geral, constituído de coordenadas muito próximas a zero, de modo que pode ser desconsiderado para fins de modelagem, sendo considerado um vetor nulo.

As componentes *Wavelet* de aproximação e detalhe foram obtidas neste trabalho a partir do *software Matlab* 8.0, que oferece várias opções de bases *Wavelet*, tais como: as famílias *daubechies* (db N), *coiflets* (coif N) e *symlets* (sym N), onde N é a ordem de decomposição e a família *biorthogonal* (bior Nr.Nd), onde Nr.Nd é uma decomposição composta, sendo Nd a ordem da decomposição e Nr a ordem da reconstrução, (DAUBECHIES, 1992).

A Tabela 1 apresenta as características das famílias *Wavelet* utilizadas neste trabalho.

TABELA 1 - CARACTERÍSTICAS DAS FAMÍLIAS WAVELET

Famílias <i>Wavelet</i>	<i>Daubechies</i>	<i>Symlets</i>	<i>Coiflets</i>	<i>Biorthogonal</i>
Propriedades	(db N)	(sym N)	(coif N)	(biorNr.Nd)
Ordem	1 (Haar), 2, ..., 45	1, 2, ..., 30	1, 2, ..., 5	1.1, 1.3, ..., 6.8
Ortogonal	Sim	Sim	Sim	Não
Suporte compacto	Sim	Sim	Sim	Sim
Largura do suporte	2N-1	2N-1	6N-1	2Nd+1
Simetria	Não	Aproximada	Aproximada	Sim
Número de momentos nulos	N	N	2N	Nr

FONTE: O autor (2015).

Para este trabalho foi fixado como nível de decomposição $r = 2$, portanto para cada base *Wavelet* foram obtidas três séries temporais que são: a série temporal que

representa a componente de aproximação indicada por $(\tilde{y}_{A_2}(t))_{t=1}^T$ e duas séries temporais que representam as componentes de detalhe representadas por $(\tilde{y}_{D_2}(t))_{t=1}^T$ e $(\tilde{y}_{D_3}(t))_{t=1}^T$.

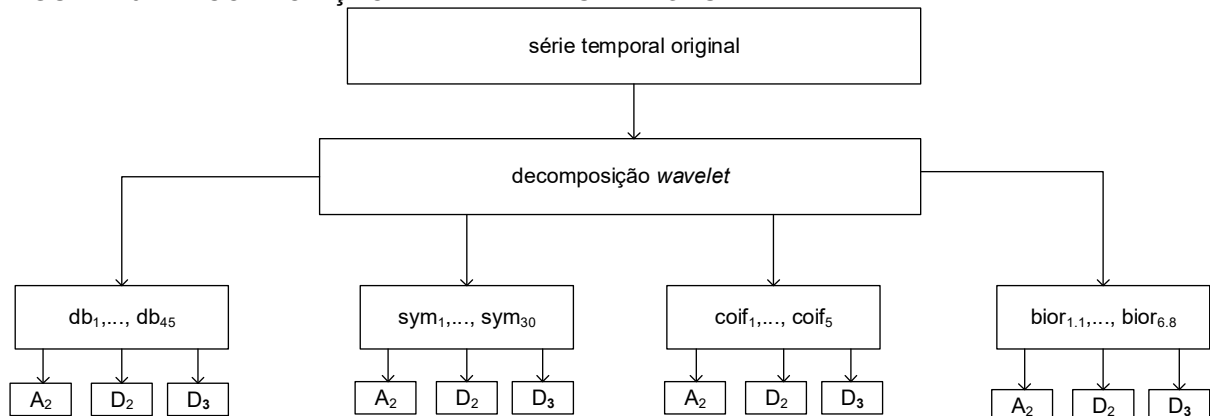
Com relação à escolha das *Wavelets*, há muitas alternativas de escolha. Na construção do método são usadas as *Wavelets Daubechies*, *Symlets*, *Coiflets* e *Biortogonais*. Não existe uma regra geral que recomende *a priori* qual será a *Wavelet* utilizada e o nível ótimo de decomposição. A escolha do nível de decomposição $r = 2$, como critério do modelo híbrido proposto, se dá pelo fato de que níveis superiores a 2 levaram a ganhos reduzidos que não justificavam o tempo dispensado com as modelagens e execução computacional. Alguns fatores que influenciam na escolha podem ser: o comportamento da série, tamanho da série, e a experiência do pesquisador, (GUTIERREZ, 2002).

Assim, para cada família *Wavelet* utilizada há uma aproximação da série temporal $(y(t))_{t=1}^T$, dada por: $(y(t))_{t=1}^T \cong (\tilde{y}_{A_2}(t))_{t=1}^T + (\tilde{y}_{D_2}(t))_{t=1}^T + (\tilde{y}_{D_3}(t))_{t=1}^T$.

Neste trabalho foram consideradas as bases: *daubechies* de momentos nulos de 1 a 45 (db1, db2,...,db45), *coiflets* de momentos nulos de 1 a 5 (coif1, coif2,..., coif5), *symlets* de momentos nulos de 1 a 30 (sym1, sym2,..., sym30) e *biorthogonal* de momentos nulos $Nr = 1$ e $Nd = 1,3$ e 5, $Nr = 2$ e $Nd = 2,4,6$, e 8, $Nr = 3$ e $Nd = 1,3,5,7$ e 9, $Nr = 4$ e $Nd = 4$, $Nr = 5$ e $Nd = 5$ e $Nr = 6$ e $Nd = 8$.

Assim, para cada série temporal a ser modelada $(y(t))_{t=1}^T$ são obtidas 255 subséries. O fluxograma da Figura 10 mostra esta etapa do método.

FIGURA 10 - DECOMPOSIÇÃO WAVELET DA SÉRIE OBSERVADA



FONTE: O autor (2015).

3.2.3 Modelagem das Componentes *Wavelet* via SVR Múltiplos Núcleos

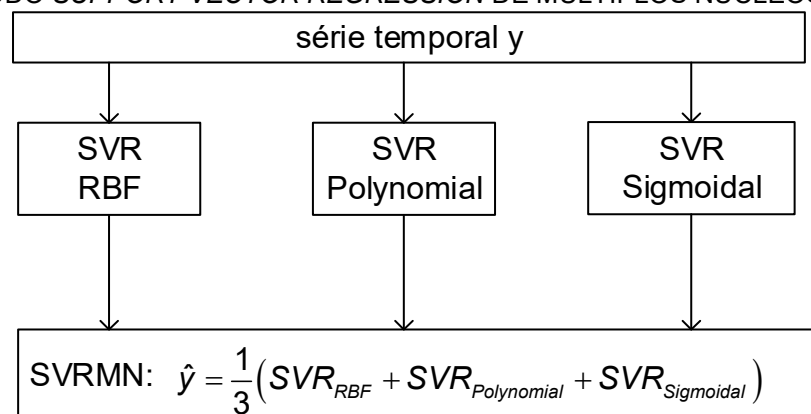
A regressão por SVR tem se mostrado eficiente na abordagem de processos não lineares (CHENG e HU, 2012; KAO *et al.*, 2013; CHEN *et al.*, 2015 e ZHU *et al.*, 2015). O processo de formação do modelo SVR utiliza a programação quadrática com restrições lineares que fornece um único valor ótimo não havendo problemas de mínimos locais. Sua solução é esparsa, uma vez que apenas os dados essenciais são utilizados para resolver a função de regressão (SMOLA e SCHÖLKOPF, 2004). Na realização do mapeamento não linear dos dados de entrada para um espaço de dimensão maior, onde a regressão linear torna-se possível, utiliza-se a abordagem baseada em funções *Kernel* (VAPNIK, 1995). Dentre as funções *Kernel* utilizadas na modelagem por SVR, destacamos as de base radial (RBF), a *Polynomial* e a *Sigmoidal*.

Nesta tese utilizamos o termo núcleo quando nos referimos às funções *Kernel*.

O método denominado SVR Múltiplos Núcleos considera uma série temporal na qual são realizadas as modelagens através do SVR núcleo RBF, SVR núcleo *Polynomial* e SVR núcleo *Sigmoidal*, separadamente.

As previsões obtidas através da combinação das previsões advindas das modelagens SVR núcleo RBF, SVR núcleo *Polynomial* e SVR núcleo *Sigmoidal* são denominadas de *Support Vector Regression* de Múltiplos Núcleos e podem ser visualizadas no fluxograma da Figura 11.

FIGURA 11 - MÉTODO *SUPPORT VECTOR REGRESSION* DE MÚLTIPLOS NÚCLEOS - SVRMN



FONTE: O autor (2015).

Da etapa anterior tem-se que para cada base *Wavelet* foram obtidas três componentes *Wavelet* que nesta etapa são modeladas pelo método SVRMN.

Assim sendo, a série temporal decomposta na etapa anterior e representada por $(y(t))_{t=1}^T \cong (\tilde{y}_{A_2}(t))_{t=1}^T + (\tilde{y}_{D_2}(t))_{t=1}^T + (\tilde{y}_{D_3}(t))_{t=1}^T$ fornece a seguinte sequência de previsões dentro e fora da amostra: $(\hat{y}_{RBF_A_2}(t))_{t=T'}^{T+h}$, $(\hat{y}_{RBF_D_2}(t))_{t=T'}^{T+h}$, $(\hat{y}_{RBF_D_3}(t))_{t=T'}^{T+h}$, $(\hat{y}_{Poly_A_2}(t))_{t=T'}^{T+h}$, $(\hat{y}_{Poly_D_2}(t))_{t=T'}^{T+h}$, $(\hat{y}_{Poly_D_3}(t))_{t=T'}^{T+h}$, $(\hat{y}_{Sigm_A_2}(t))_{t=T'}^{T+h}$, $(\hat{y}_{Sigm_D_2}(t))_{t=T'}^{T+h}$ e $(\hat{y}_{Sigm_D_3}(t))_{t=T'}^{T+h}$.

A previsão da série $(y(t))_{t=1}^T$ é dada pela Equação (20):

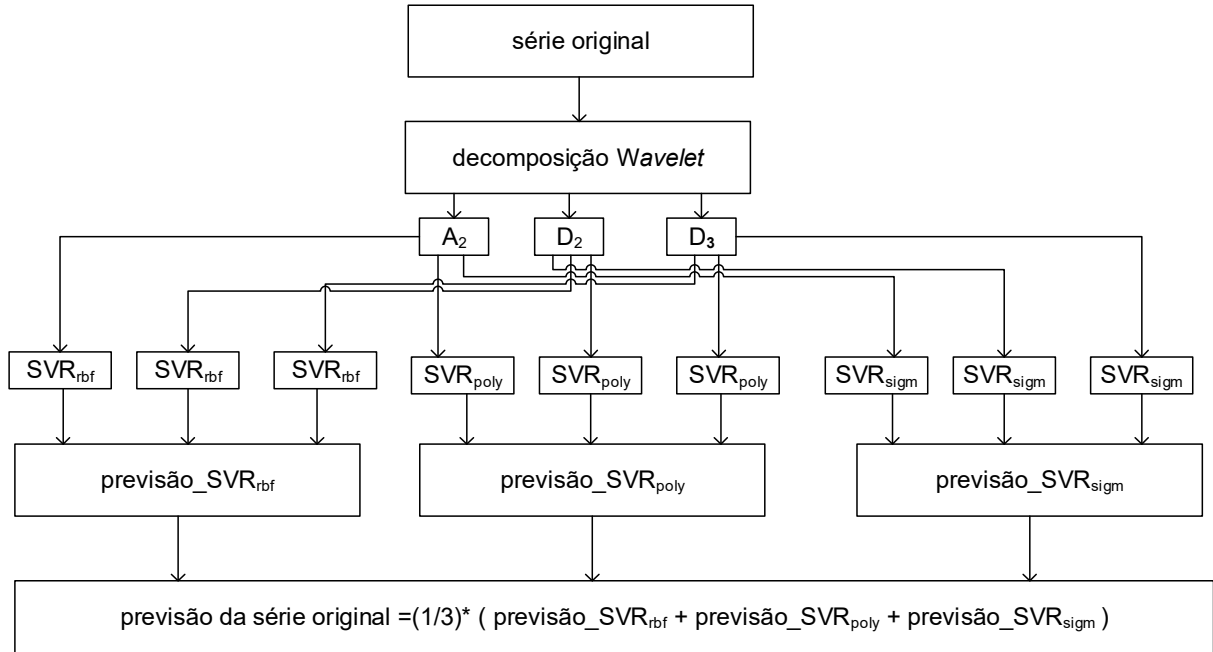
$$\begin{aligned} (\hat{y}_{BaseWavelet}(t))_{t=T'}^{T+h} = & \frac{1}{3} [\hat{y}_{RBF_A_2}(t) + \hat{y}_{RBF_D_2}(t) + \hat{y}_{RBF_D_3}(t)]_{t=T'}^{T+h} + \\ & + \frac{1}{3} [\hat{y}_{Poly_A_2}(t) + \hat{y}_{Poly_D_2}(t) + \hat{y}_{Poly_D_3}(t)]_{t=T'}^{T+h} + \\ & + \frac{1}{3} [\hat{y}_{Sigm_A_2}(t) + \hat{y}_{Sigm_D_2}(t) + \hat{y}_{Sigm_D_3}(t)]_{t=T'}^{T+h} \end{aligned} \quad (20)$$

Onde: h é o horizonte de previsão; T' são os graus de liberdade perdidos pelo modelo SVR; e $T' < T$ (T' não necessariamente igual em cada previsão).

Foram geradas as seguintes previsões para cada base *Wavelet*: $(\hat{y}_{db_i}(t))_{t=T'}^{T+h}$, $i=1,2,...,45$, $(\hat{y}_{sym_i}(t))_{t=T'}^{T+h}$, $i=1,2,...,30$, $(\hat{y}_{coif_i}(t))_{t=T'}^{T+h}$, $i=1,2,...,5$, $(\hat{y}_{bior_i}(t))_{t=T'}^{T+h}$, $i=1.1,1.3,1.5,2.2,2.4,2.6,2.8,3.1,3.2,3.5,3.7,3.9,4.4,5.5,6.8$.

Para a modelagem via SVR foi utilizada uma biblioteca para SVR para *Matlab* denominada de LIBSVM proposta por Chang e Lin (2015), bem como rotinas que foram necessárias.

Segue no fluxograma apresentado na Figura 12 as etapas da previsão das CW pelo método *Support Vector Regression* Múltiplos Núcleos (SVRMN).

FIGURA 12 - PREVISÃO DAS COMPONENTES *WAVELET* POR SVRMN

FONTE: O autor (2015).

3.2.4 Combinação Linear das Bases *Wavelets* Previstas por SVRMN

Das previsões obtidas na etapa anterior são selecionadas as modelagens que apresentaram o menor erro quadrático médio (MSE) com base nos dados de validação, para cada família *Wavelet*, considerada.

Logo são selecionadas as seguintes previsões: $\left(\hat{y}_{db_{MelhorValidação}}(t)\right)_{t=T''}^T$, $\left(\hat{y}_{sym_{MelhorValidação}}(t)\right)_{t=T''}^T$, $\left(\hat{y}_{coif_{MelhorValidação}}(t)\right)_{t=T''}^T$ e $\left(\hat{y}_{bior_{MelhorValidação}}(t)\right)_{t=T''}^T$ com $T'' < T$.

Faz-se nesta etapa a combinação linear das previsões obtidas pelo método SVRWMN, para obter a previsão da componente não linear $(N(t))_{t=1}^T$ do método híbrido proposto, gerando a série $(\hat{N}(t))_{t=T''}^T$, sendo a combinação descrita na Equação (21).

$$\begin{aligned}
 (\hat{N}(t))_{t=T''}^T = & \rho_1 \times \left(\hat{y}_{db_{MelhorValidação}}(t)\right)_{t=T''}^T + \rho_2 \times \left(\hat{y}_{sym_{MelhorValidação}}(t)\right)_{t=T''}^T + \\
 & + \rho_3 \times \left(\hat{y}_{coif_{MelhorValidação}}(t)\right)_{t=T''}^T + \rho_4 \times \left(\hat{y}_{bior_{MelhorValidação}}(t)\right)_{t=T''}^T
 \end{aligned} \quad (21)$$

Onde: $\hat{N}(t)$ é a previsão combinada da componente não linear $N(t)$; e ρ_i , $i=1,..,4$ são parâmetros a serem determinados com a otimização do problema de

programação não linear dado na Equação (22), cuja função objetivo consiste na minimização do erro quadrático médio (MSE).

$$\begin{aligned} \text{Min } MSE &= \frac{1}{T - T''} \sum_{t=T''}^T \left(y(t) - \hat{N}(t) \right)^2 \\ \text{s.a } \rho_1, \rho_2, \rho_3, \rho_4 &\quad \text{são irrestritas} \end{aligned} \quad (22)$$

Para a otimização do Problema (22) de programação não linear foi usado o pacote *solver* do software *Excel* 2013.

As previsões obtidas nesta etapa fazem parte do método denominado *Support Vector Regression Wavelet* de Múltiplos Núcleos, ou simplesmente SVRWMN.

3.2.5 Previsões Pontuais

Nesta etapa tomam-se as previsões lineares $\left(\hat{L}(t) \right)_{t=T''}^{T+h}$ e não lineares $\left(\hat{N}(t) \right)_{t=T''}^{T+h}$, para a obtenção das previsões pontuais para cada instante t . A Equação (23) mostra a geração das previsões oriundas do método proposto, gerando desta forma previsões dentro e fora da amostra, que será denotado por $\left(\hat{y}_{SSVRWMN}(t) \right)_{t=T''}^{T+h}$, onde cada $\hat{y}(t)$ é, de fato, um conjunto de informações de diferentes fontes.

$$\left(\hat{y}_{SSVRWMN}(t) \right)_{t=T''}^{T+h} = \frac{1}{2} \left(\hat{L}(t) + \hat{N}(t) \right)_{t=T''}^{T+h} \quad (23)$$

Portanto, a lista $\left(\hat{y}_{SSVRWMN}(t) \right)_{t=T''}^{T+h}$ de previsões, dentro e fora da amostra (previsões *multi step*), consiste nos resultados do método proposto, referido como SARIMA *Support Vector Regression Wavelet* de Múltiplos Núcleos (SSVRWMN).

As previsões dentro da amostra $\left(\hat{y}_{SSVRWMN}(t) \right)_{t=T''}^T$ apresentam simultaneamente informações provenientes de modeladores que capturam estruturas de autodependência lineares e não lineares e podem ser consideradas como uma versão filtrada da série temporal $y(t)$, tanto por um filtro linear (etapa 1) quanto por um filtro não linear (etapas 3 e 4).

Deste modo, os erros de previsão dentro da amostra $\left(e(t) \right)_{t=T''}^T = \left(y(t) - \hat{y}_{SSVRWMN}(t) \right)_{t=T''}^T$ consistem, de fato, em uma realização de um processo estocástico tipo ruído branco (confirmada pelos testes de

autocorrelação residual, independência estatística BDS e de estacionariedade *Dickey-Fuller*), (HAMILTON, 1994).

3.2.6 Intervalo de Confiança

Obtidos os resíduos na amostra de treinamento $(e(t))_{t=T^n}^T = (y(t) - \hat{y}_{SSVRWMN}(t))_{t=T^n}^T$ na etapa 3.2.5, e utilizando a técnica *Bootstrap* residual sugerida por Tibshirani (1996), revisada na seção 2.6, estima-se o erro padrão do t -ésimo valor predito usando $\left[\frac{1}{B-1} \sum_{b=1}^B (\hat{y}^b(t) - \bar{\hat{y}}^b(t))^2 \right]^{1/2}$, onde

$\bar{\hat{y}}^b(t) = \frac{1}{B} \sum_{b=1}^B \hat{y}^b(t)$. Sendo o intervalo de confiança dado pela Equação (24).

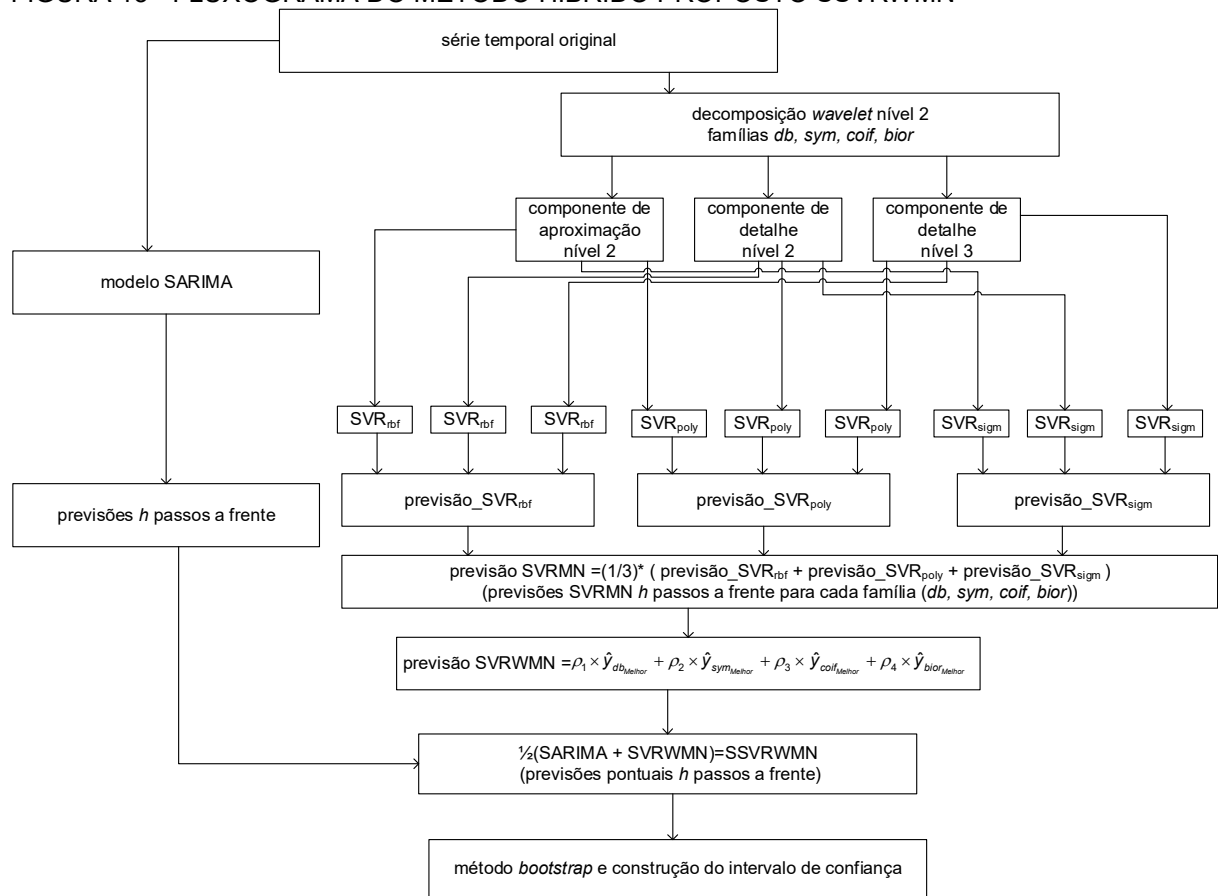
$$\bar{\hat{y}}^b(t) - t_{1-\frac{\alpha}{2}, gl} \hat{\sigma}_g(x) \leq f(\mathbf{x}, \mathbf{w}) \leq \bar{\hat{y}}^b(t) + t_{1-\frac{\alpha}{2}, gl} \hat{\sigma}_g(x) \quad (24)$$

Onde: $\hat{\sigma}_g(x) = \left[\frac{1}{B-1} \sum_{b=1}^B (\hat{y}^b(t) - \bar{\hat{y}}^b(t))^2 \right]^{1/2}$ é o erro padrão estimado, $t_{1-\frac{\alpha}{2}, gl}$ provêm da

distribuição t de *Student* com nível de significância α e gl são os graus de liberdade. Sendo definidos os graus de liberdade como sendo a diferença entre o tamanho do passo (número de previsões passos à frente) e a quantidade de modelos utilizados, ou seja, $gl = h - 2$, $h > 3$, onde $h = 12$, representa os passos à frente a serem considerados na previsão, e considerando a quantidade de modelos igual a 2, um linear e outro não linear.

A Figura 13 apresenta um fluxograma com as etapas do método híbrido proposto denominado de SARIMA *Support Vector Regression Wavelet* de Múltiplos Núcleos - SSVRWMN.

FIGURA 13 - FLUXOGRAMA DO MÉTODO HÍBRIDO PROPOSTO SSVRWMN



FONTE: O autor (2015).

4 RESULTADOS E DISCUSSÃO

Neste capítulo, são mostrados os resultados da aplicação do método híbrido proposto às séries que auxiliam no monitoramento do movimento de tombamento do bloco I10 da barragem da Usina Hidrelétrica de Itaipu, bem como a discussão dos resultados. Os resultados obtidos da modelagem das séries temporais provenientes das aferições dos extensômetros, das bases de alongâmetro, do piezômetro e do pêndulo direto pelo método híbrido SSVRWMN, foram comparados com outras abordagens já consagradas na literatura, tais como a modelagem Box e Jenkins, *Support Vector Regression* e o composto SARIMA-SVR.

Na primeira etapa deste trabalho para cada série temporal foi realizado o tratamento das informações, para serem estruturadas de acordo com a metodologia de previsão e optou-se por trabalhar com o período de 1994-2014 com valores mensais. Dos 252 valores que cada série temporal possui, os 228 primeiros dados foram utilizados no ajuste dos modelos-base (SARIMA e SVR, SSVRWMN), os 12 valores seguintes foram reservados para validação e os 12 últimos valores referentes ao ano de 2014 para teste. A metodologia usada é de previsões *multi step ahead*, ou seja, h passos à frente, nesta aplicação $h = 12$, portanto o horizonte de previsão coincide com o total de passos.

Para a avaliação dos métodos, foram utilizados os erros MAPE (*mean absolute percent error*), MSE (*mean square error*) e MAE (*mean absolute error*), (HAMILTON, 1994) representados nas Equações (25), (26) e (27), respectivamente.

$$MAPE = \frac{1}{T} \sum_{t=1}^T \left| \frac{y(t) - \hat{y}(t)}{y(t)} \right| \quad (25)$$

$$MSE = \frac{1}{T} \sum_{t=1}^T (y(t) - \hat{y}(t))^2 \quad (26)$$

$$MAE = \frac{1}{T} \sum_{t=1}^T |y(t) - \hat{y}(t)| \quad (27)$$

4.1.1 Pêndulo Direto

Denotaremos a série do pêndulo direto a ser modelada, de tamanho $T = 252$, por $(y_{co}(t))_{t=1}^{252}$, sendo reservados $t = 1, 2, \dots, 228$ para ajuste e $t = 229, \dots, 240$ para validação do modelo.

Seguindo as etapas do método SSVRWMN proposto, tem-se:

Etapa 1: Foi realizada na série $(y_{co}(t))_{t=1}^{240}$ a modelagem através de um modelo SARIMA distinto, gerando previsões $(\hat{y}_{co}(t))_{t=10}^{240}$ dentro da amostra de treino e previsões na amostra de teste num horizonte de 12 passos à frente $(\hat{y}_{co}(t))_{t=241}^{252}$. Estas previsões são consideradas pelo método híbrido como as previsão da componente linear $(\hat{L}_{co}(t))_{t=10}^{240+12}$.

Para modelagem SARIMA foi utilizado o *software EViews*, sendo feita a análise gráfica da série temporal e identificado o modelo apropriado. A definição das ordens dos modelos ocorreram com a análise dos gráficos das funções de autocorrelação FAC, autocorrelação parcial FACP, resíduos e testes com diversas opções de ordens p, d, q . Os valores encontrados são apresentados na Tabela 2.

TABELA 2 - MODELAGEM SARIMA CO-I-2/X

Variável	Coefficiente	Erro padrão	Estatística-t	Probabilidade
AR(12)	1.001462	0.006894	145.2634	0.0000
MA(1)	-0.632463	0.049493	-12.77889	0.0000
MA(3)	-0.416386	0.054726	-7.608606	0.0000
MA(9)	0.085333	0.036069	2.365816	0.0189
SMA(12)	-0.843251	0.038201	-22.07423	0.0000
R-quadrado	0.832369	Média da variável dependente		0.009692
R-quadrado ajustado	0.829348	Desvio padrão da variável dependente		1.260694
Erro padrão da regressão	0.520793	Akaike		1.554850
Soma dos resíduos ao quadrados	60.21192	Schwarz		1.630290
Log likelihood	-171.4755	Hannan-Quinn		1.585291
Durbin-Watson	1.901669			

FONTE: O autor (2015).

Etapa 2: Foi realizada na série temporal $(y_{co}(t))_{t=1}^{240}$ a decomposição ortogonal *Wavelet* de nível $r = 2$, considerando as bases *daubechies* (db 1,2,...,45), *coiflets* (coif 1,2,...,5), *symlets* (sym 1,2,...,30) e *biorthogonal* (1.1, 1.3, ..., 6.8), gerando uma componente de aproximação que é a representação da série original em baixa

frequência, e é representada por $(\tilde{y}_{co_A_2}(t))_{t=1}^{240}$ e duas componentes de detalhe que são séries de altas frequências (séries mais ruidosas), indicadas por $(\tilde{y}_{co_D_2}(t))_{t=1}^T$ e $(\tilde{y}_{co_D_3}(t))_{t=1}^T$. Sendo, portanto, gerado para a série temporal $(y_{co}(t))_{t=1}^{240}$ um total de 285 subséries.

Tem-se que a série temporal $(y_{co}(t))_{t=1}^{240}$ pode ser aproximada pela soma das subséries geradas pela decomposição ortogonal *Wavelet* (TEIXEIRA JR. *et al.*, 2015), e é representada por $(y_{co}(t))_{t=1}^{240} \cong (\tilde{y}_{co_A_2}(t))_{t=1}^{240} + (\tilde{y}_{co_D_2}(t))_{t=1}^{240} + (\tilde{y}_{co_D_3}(t))_{t=1}^{240}$.

Segue na Tabela 3, para a série temporal do pêndulo direto $(y_{co}(t))_{t=1}^{240}$, a listagem das séries modeladas.

TABELA 3 - SÉRIES MODELADAS VIA SVRMN

Base	Série aproximada pela decomposição <i>Wavelet</i>
db1	$(y_{db1_co}(t))_{t=1}^{240} \cong (\tilde{y}_{db1_A_2}(t))_{t=1}^{240} + (\tilde{y}_{db1_D_2}(t))_{t=1}^{240} + (\tilde{y}_{db1_D_3}(t))_{t=1}^{240}$
⋮	⋮
db45	$(y_{db45_co}(t))_{t=1}^{240} \cong (\tilde{y}_{db45_A_2}(t))_{t=1}^{240} + (\tilde{y}_{db45_D_2}(t))_{t=1}^{240} + (\tilde{y}_{db45_D_3}(t))_{t=1}^{240}$
coif1	$(y_{coif1_co}(t))_{t=1}^{240} \cong (\tilde{y}_{coif1_A_2}(t))_{t=1}^{240} + (\tilde{y}_{coif1_D_2}(t))_{t=1}^{240} + (\tilde{y}_{coif1_D_3}(t))_{t=1}^{240}$
⋮	⋮
coif5	$(y_{coif5_co}(t))_{t=1}^{240} \cong (\tilde{y}_{coif5_A_2}(t))_{t=1}^{240} + (\tilde{y}_{coif5_D_2}(t))_{t=1}^{240} + (\tilde{y}_{coif5_D_3}(t))_{t=1}^{240}$
sym1	$(y_{sym1_co}(t))_{t=1}^{240} \cong (\tilde{y}_{sym1_A_2}(t))_{t=1}^{240} + (\tilde{y}_{sym1_D_2}(t))_{t=1}^{240} + (\tilde{y}_{sym1_D_3}(t))_{t=1}^{240}$
⋮	⋮
sym30	$(y_{sym30_co}(t))_{t=1}^{240} \cong (\tilde{y}_{sym30_A_2}(t))_{t=1}^{240} + (\tilde{y}_{sym30_D_2}(t))_{t=1}^{240} + (\tilde{y}_{sym30_D_3}(t))_{t=1}^{240}$
bior1.1	$(y_{bior1.1_co}(t))_{t=1}^{240} \cong (\tilde{y}_{bior1.1_A_2}(t))_{t=1}^{240} + (\tilde{y}_{bior1.1_D_2}(t))_{t=1}^{240} + (\tilde{y}_{bior1.1_D_3}(t))_{t=1}^{240}$
⋮	⋮
bior 6.8	$(y_{bior6.8_co}(t))_{t=1}^{240} \cong (\tilde{y}_{bior6.8_A_2}(t))_{t=1}^{240} + (\tilde{y}_{bior6.8_D_2}(t))_{t=1}^{240} + (\tilde{y}_{bior6.8_D_3}(t))_{t=1}^{240}$

FONTE: O autor (2015).

Etapa 3: Nesta etapa, para cada uma das 285 séries obtida pela decomposição *Wavelet* são realizadas as previsões via *Support Vector Regression* de Múltiplos Núcleos.

Foram considerados, para compor o método, os três principais núcleos, que são o RBF, o polinomial, e o *Sigmoidal*, (SMOLA e SCHÖLKOPF, 2004).

Por exemplo, para a série $(y_{db1_co}(t))_{t=1}^{240}$, foram geradas as previsões,

$$\begin{aligned} (\hat{y}_{db1_co_RBF}(t))_{t=12}^{240+12} &= (\hat{y}_{db1_co_RBF_{A_2}}(t))_{t=12}^{240+12} + (\hat{y}_{db1_co_RBF_{D_2}}(t))_{t=12}^{240+12} + (\hat{y}_{db1_co_RBF_{D_3}}(t))_{t=12}^{240+12}, \\ (\hat{y}_{db1_co_Poly}(t))_{t=12}^{240+12} &= (\hat{y}_{db1_co_Poly_{A_2}}(t))_{t=12}^{240+12} + (\hat{y}_{db1_co_Poly_{D_2}}(t))_{t=12}^{240+12} + (\hat{y}_{db1_co_Poly_{D_3}}(t))_{t=12}^{240+12} \text{ e} \\ (\hat{y}_{db1_co_Sigm}(t))_{t=12}^{240+12} &= (\hat{y}_{db1_co_Sigm_{A_2}}(t))_{t=12}^{240+12} + (\hat{y}_{db1_co_Sigm_{D_2}}(t))_{t=12}^{240+12} + (\hat{y}_{db1_co_Sigm_{D_3}}(t))_{t=12}^{240+12}. \end{aligned}$$

Sendo a previsão da série $(y_{db1_co}(t))_{t=1}^{240}$, a média das previsões, ou seja,

$$(\hat{y}_{db1_co}(t))_{t=12}^{240+12} = \frac{1}{3}(\hat{y}_{db1_co_RBF}(t))_{t=12}^{240+12} + \frac{1}{3}(\hat{y}_{db1_co_Poly}(t))_{t=12}^{240+12} + \frac{1}{3}(\hat{y}_{db1_co_Sigm}(t))_{t=12}^{240+12}.$$

Este processo foi repetido para todas as 95 decomposições *Wavelet*.

Para obtenção dos parâmetros ótimos do modelo SVR, em cada caso, os dados da série temporal reservado para o ajuste foram subdivididos em treino e validação, sendo escolhido o modelo que apresentou um menor *MSE* no conjunto de validação, sendo a cardinalidade do conjunto de validação para cada caso igual a 12.

Segue na Tabela 4, os dois melhores resultados obtidos para cada família *Wavelet* e a estatística *MSE* da amostra de validação.

TABELA 4 - DOIS MELHORES RESULTADOS PARA CADA FAMÍLIA WAVELET (CO-I-2/X)

Família	Base	Validação
		MSE
<i>Daubechies</i>	db6	0,02545
	db40	0,01639
<i>Symlets</i>	sym19	0,03968
	sym23	0,02565
<i>Coiflets</i>	coif3	0,17120
	coif4	0,25507
<i>Biorthogonal</i>	bior3.1	0,03982
	bior6.8	0,07165

FONTE: O autor (2015).

O método proposto determinou a seguinte sequência de previsões:

$$\begin{aligned} &(\hat{y}_{db1_co}(t))_{t=12}^{240+12}, i=1,2,...,45, (\hat{y}_{sym1_co}(t))_{t=12}^{240+12}, i=1,2,...,30, (\hat{y}_{coif1_co}(t))_{t=10}^{240+12}, i=1,2,...,5 \text{ e} \\ &(\hat{y}_{bior1_co}(t))_{t=12}^{240+12}, i=1.1,1.3,1.5,2.2,2.4,2.6,2.8,3.1,3.2,3.5,3.7,3.9,4.4,5.5 \text{ e } 6.8. \end{aligned}$$

Da Tabela 3, observa-se que as modelagens escolhidas são aquelas que apresentaram a menor estatística de aderência MSE, e são elas para a série CO-I-2/X as bases db40, sym23, coif3 e bior3.1.

Segue na Tabela 5, o intervalo de busca dos parâmetros utilizados na modelagem de cada SVR.

TABELA 5 - PARÂMETROS SVR

Kernel	gamma	coef0	degree	cost	epsilon	Window
RBF	[0,1] passo 0,01	-	-	[1,100] passo 1	0,01	[1,12] passo 1
Polinomial	[0,1] passo 0,01	[0,3] passo 1	3	[1,100] passo 1	0,01	[1,12] passo 1
<i>Sigmoidal</i>	[0,1] passo 0,01	[-2,3] passo 1	-	[1,100] passo 1	0,01	[1,12] passo 1

FONTE: O autor (2015).

Etapa 4: Nesta etapa foram combinadas as previsões das melhores modelagens obtidas quando comparada a estatística MSE no conjunto de validação referente a cada família *Wavelet*. A combinação é representada por:

$$(\hat{y}_{co}(t))_{t=12}^{240} = \left[\rho_1 \times (\hat{y}_{db40_co}(t)) + \rho_2 \times (\hat{y}_{sym23_co}(t)) + \rho_3 \times (\hat{y}_{coif3_co}(t)) + \rho_4 \times (\hat{y}_{bior3.1_co}(t)) \right]_{t=12}^{240}$$

onde as constantes adaptativas assumem os seguintes valores $\rho_1=0,458526$, $\rho_2=0,085159$, $\rho_3=0,251612$ e $\rho_4=0,221247$, após a minimização do erro quadrático médio (MSE).

São obtidas nesta etapa, as previsões do modelo SVR *Wavelet* múltiplos núcleos, ou seja, da componente não linear $(\hat{N}_{co}(t))_{t=12}^{240}$ do modelo híbrido proposto.

Etapa 5: Nesta etapa tomam-se as previsões obtidas pelo modelo linear (SARIMA) $(\hat{L}_{co}(t))_{t=10}^{240+12}$ e pelo modelo não linear (SVRWMN) $(\hat{N}_{co}(t))_{t=12}^{240+12}$ e faz-se a média, para a obtenção das previsões pontuais para cada t , conforme: $(\hat{y}_{co}(t))_{t=12}^{240+12} = \frac{1}{2}(\hat{L}_{co}(t) + \hat{N}_{co}(t))_{t=12}^{240+12}$, onde cada $\hat{y}(t)$ é, de fato, um conjunto de informações de diferentes fontes.


O método híbrido SSVRWMN apresenta em sua estrutura de autodependência informações lineares e não lineares e pode ser considerado como uma versão filtrada

da série temporal $y(t)$, tanto por um filtro linear (etapa 1) quanto por um filtro não linear (etapas 3 e 4).

Portanto, a lista $(\hat{y}_{co}(t))_{t=12}^{240+12} = \frac{1}{2}(\hat{L}_{co}(t) + \hat{N}_{co}(t))_{t=12}^{240+12}$ de previsões, dentro e fora da amostra (previsões *multi step*), consiste nos resultados do método proposto referido como *SARIMA Support Vector Regression Wavelet* de Múltiplos Núcleos (SSVRWMN), para a série do pêndulo direto, CO-I-2/X.

O gráfico das previsões fora da amostra (dados de teste) pelo método híbrido proposto SSVRWMN para a série temporal $y_{co}(t)$ está representado na Figura 14.

FIGURA 14 - GRÁFICO DA SÉRIE DO PÊNDULO E PREVISÕES PELO MÉTODO SSVRWMN.



FONTE: O autor (2015).

Nesta etapa, é possível fazer a comparação das previsões do método proposto com as previsões obtidas pelo método SARIMA, SVR e combinação SARIMA-SVR. As estatísticas de aderência comparadas são: MSE, MAPE e MAE, conforme apresentadas na Tabela 6.

TABELA 6 - COMPARATIVO MSE, MAPE E MAE PARA A SÉRIE CO-I-2/X *MULTI STEP* $h=12$

Método	MSE	MAPE	MAE
SARIMA	0,3615	12,7%	0,4581
SVR	0,8398	19,8%	0,8419
SARIMA-SVR	0,7146	18,6%	0,7801
SSVRWMN	0,2157	11,8%	0,4149

FONTE: O autor (2015).

Da Tabela 6, verifica-se que o método proposto SSVRWMN obteve nas previsões da série temporal do instrumento CO-I-2/X uma redução nas três estatísticas de aderência MSE, MAPE e MAE, em relação a todos os demais métodos preditivos listados. Comparando-o ao segundo melhor resultado (a saber, o método SARIMA), a redução relativa foi de, aproximadamente, 40,3% na medida MSE, de 9,4% na medida MAE e 7,1% na medida MAPE.


Tais resultados demonstram a eficiência preditiva do método proposto diante de abordagens consagradas na literatura de séries temporais, como: SARIMA, SVR e o híbrido SARIMA-SVR, no presente caso.

ETAPA 6: Após obter a série dos resíduos $(r_{co}(t))_{t=12}^{240} = (y_{co}(t) - \hat{y}_{co}(t))_{t=12}^{240}$, utilizou-se o processo *Bootstrap* residual conforme seção 2.6, para obtenção do intervalo de confiança.

A quantidade B de amostras *Bootstrap*, conforme Tibshirani (1996), pertence ao intervalo [20,200], enquanto Montgomery e Runger (2003) definem o número B de amostras *Bootstrap* através da observação da variação do desvio padrão do estimador *Bootstrap*. Uma pequena variabilidade ou estabilidade desse valor indica o valor de B mais apropriado.

A Figura 15 ilustra o intervalo de confiança obtido através do procedimento *Bootstrap*.

FIGURA 15 - INTERVALO DE CONFIANÇA PARA A SÉRIE TEMPORAL CO-I-2/X



FONTE: O autor (2015).

4.1.2 Piezômetro

Denotaremos a série do piezômetro a ser modelada, por $(y_{ps}(t))_{t=1}^{252}$. Seguindo as etapas do método proposto SSVRWMN, tem-se:

Etapa 1: modelagem via SARIMA da série $(y_{ps}(t))_{t=1}^{240}$, gerando previsões $(\hat{y}_{ps}(t))_{t=10}^{240}$ dentro da amostra de treino e previsões na amostra de teste num horizonte igual a 12, $(\hat{y}_{ps}(t))_{t=241}^{252}$. Estas previsões são consideradas pelo método híbrido como as previsão da componente linear $(\hat{L}_{ps}(t))_{t=12}^{240+12}$.

Os valores encontrados na modelagem estão apresentados na Tabela 7.

TABELA 7 - MODELAGEM SARIMA PS-I-22

Variável	Coeficiente	Erro padrão	Estatística-t	Probabilidade
AR(1)	0.589922	0.044582	13.23221	0.0000
AR(10)	0.410084	0.044583	9.198260	0.0000
MA(1)	-0.262589	0.077803	-3.375077	0.0009
MA(10)	-0.959577	0.008765	-109.4830	0.0000
MA(11)	0.270075	0.076805	3.516387	0.0005
R-quadrado	0.401165	Média da variável dependente		164.5615
R-quadrado ajustado	0.390519	Desvio padrão da variável dependente		0.076879
Erro padrão da regressão	0.060019	Akaike		-2.766822
Soma dos resíduos ao quadrados	0.810505	Schwarz		-2.692081
Log likelihood	323.1845	Hannan-Quinn		-2.736673
Durbin-Watson	1.971314			

FONTE: O autor (2015).

Etapa 2: Foi realizada na série temporal $(y_{ps}(t))_{t=1}^{240}$ a decomposição ortogonal *Wavelet* de nível $r = 2$, considerando as bases *daubechies* (db 1,2,...,45), *coiflets* (coif 1,2,...,5), *symlets* (sym 1,2,...,30) e *biorthogonal* (1.1, 1.3, ..., 6.8).

Etapa 3: Nesta etapa para cada uma das 285 séries obtidas pela decomposição *Wavelet* são realizadas as previsões via *Support Vector Regression* de Múltiplos Núcleos.

Para obtenção dos parâmetros ótimos do modelo SVR, em cada caso, os dados da série temporal reservada para o treinamento foram subdivididos em treino e validação, sendo escolhido o modelo que apresentava um menor *MSE* no conjunto de validação, sendo a cardinalidade do conjunto de validação para cada caso igual a 12.

Segue na Tabela 8, os dois melhores resultados obtidos para cada família *Wavelet* e a estatísticas *MSE* da amostra de validação.

TABELA 8 - DOIS MELHORES RESULTADOS PARA CADA FAMILIA WAVELET (PS-I-22)

Família	Base	Validação
		MSE
<i>Daubechies</i>	db10	0,00006624
	db19	0,00006864
<i>Symlets</i>	sym12	0,00006288
	sym15	0,00006595
<i>Coiflets</i>	coif3	0,00013086
	coif5	0,00013105
<i>Biorthogonal</i>	bior3.5	0,00008236
	bior3.9	0,00005207

FONTE: O autor (2015).

Da Tabela 8, observa-se que as modelagens escolhidas são aquelas que apresentaram menor *MSE*, e são elas para a série PS-I-22 as bases db10, sym12, coif3 e bior3.9.

Etapa 4: Nesta etapa foram combinadas as previsões das melhores modelagens obtidas quando comparada a estatística de aderência MSE no conjunto de validação referente a cada família *Wavelet*. A combinação é representada por:

$$\left(\hat{y}_{ps}(t)\right)_{t=12}^{240} = \left[\rho_1 \times \left(\hat{y}_{db10_ps}(t)\right) + \rho_2 \times \left(\hat{y}_{sym12_ps}(t)\right) + \rho_3 \times \left(\hat{y}_{coif3_ps}(t)\right) + \rho_4 \times \left(\hat{y}_{bior3.5_ps}(t)\right) \right]_{t=12}^{240}$$

onde as constantes adaptativas assumem os seguintes valores $\rho_1=0,856198$, $\rho_2=0,94482$, $\rho_3=0,746553$ e $\rho_4=-1,54757$, após a minimização do erro quadrático médio (MSE). São obtidas nesta etapa, as previsões do modelo SVR *Wavelet* de Múltiplos Núcleos, ou seja, da componente não linear $\left(\hat{N}_{ps}(t)\right)_{t=12}^{240}$ do modelo híbrido proposto.

Etapa 5: Nesta etapa tomam-se as previsões obtidas pelo modelo linear (SARIMA) $\left(\hat{L}_{ps}(t)\right)_{t=12}^{240+12}$ e pelo modelo não linear (SVRWMN) $\left(\hat{N}_{ps}(t)\right)_{t=12}^{240+12}$ e


determina-se a média para a obtenção das previsões pontuais para cada t , conforme:

$$\left(\hat{y}_{ps}(t)\right)_{t=12}^{240+12} = \frac{1}{2} \left(\hat{L}_{ps}(t) + \hat{N}_{ps}(t) \right)_{t=12}^{240+12}, \text{ onde cada } \hat{y}(t) \text{ é, de fato, um conjunto de}$$

informações de diferentes fontes e os resultados dentro e fora da amostra (previsões *multi step*), consistem nos resultados do método proposto (SSVRWMN), para a série, provenientes das aferições do piezômetro PS-I-22.

O gráfico das previsões fora da amostra (dados de teste) pelo método híbrido proposto SSVRWMN para a série temporal y_{ps} está representado na Figura 16.

FIGURA 16 - GRÁFICO DA SÉRIE DO PIEZÔMETRO E PREVISÕES PELO MÉTODO SSVRWMN.



FONTE: O autor (2015).

Nesta etapa, é possível fazer a comparação das previsões do método proposto com as previsões obtidas pelo método SARIMA, SVR e combinação SARIMA-SVR, referentes às estatísticas MSE, MAPE e MAE conforme Tabela 9.

TABELA 9 - COMPARATIVO MSE, MAPE E MAE PARA A SÉRIE PS-I-22 *MULTI STEP* $h=12$

Método	MSE	MAPE	MAE
SARIMA	0,002178	0,0233%	0,038419
SVR	0,001405	0,0188%	0,031070
SARIMA-SVR	0,001712	0,0208%	0,034352
SSVRWMN	0,000855	0,0148%	0,024461


FONTE: O autor (2015).

Da Tabela 9, verifica-se que o método proposto SSVRWMN obteve nas previsões da série temporal do instrumento PS-I-22 uma redução nas três estatísticas de aderência MSE, MAPE e MAE, em relação a todos os demais métodos preditivos listados. Comparando-o ao segundo melhor resultado (a saber, o método SVR), a redução relativa foi de, aproximadamente, 39,1% na medida de acurácia MSE.

ETAPA 6: Nesta etapa, após obter o resíduo $(r_{ps}(t))_{t=12}^{240} = (y_{ps}(t) - \hat{y}_{ps}(t))_{t=12}^{240}$, aplica-se o *Bootstrap* residual para geração de cenários e obtenção do intervalo de confiança.

A Figura 17 ilustra o intervalo de confiança obtido através do procedimento *Bootstrap* para a série PS-I-22.

FIGURA 17 - INTERVALO DE CONFIANÇA PARA A SÉRIE TEMPORAL PS-I-22



FONTE: O autor (2015).

4.1.3 Base de Alongâmetro

Sejam as séries temporais provenientes do instrumento base de alongâmetro JS-I-31/deslizamento que denotaremos por $(y_{js_31d}(t))_{t=1}^{252}$ e outra proveniente da base de alongâmetro JS-I-32/assentamento que será designada por $(y_{js_32a}(t))_{t=1}^{252}$, ambas de tamanho $T = 252$, sendo reservados $t = 1, 2, \dots, 240$ para ajuste do modelo. Seguindo as etapas do método proposto SSVRWMN, tem-se:

Etapa 1: Foi realizada nas séries $(y_{js_31d}(t))_{t=1}^{252}$ e $(y_{js_32a}(t))_{t=1}^{252}$ a modelagem através de um modelo SARIMA distinto, gerando as seguintes sequências de previsões para cada série, $(\hat{y}_{js_31d}(t))_{t=25}^{240+12}$ e $(\hat{y}_{js_32a}(t))_{t=12}^{240+12}$; estas previsões são consideradas pelo método híbrido como as previsões da componente linear representadas para cada série como $(\hat{L}_{js_31d}(t))_{t=25}^{240+12}$ e $(\hat{L}_{js_32a}(t))_{t=12}^{240+12}$.

Os valores encontrados na modelagem da série referente ao instrumento JS-I-31/deslizamento são apresentados na Tabela 10 e os referentes ao instrumento JS-I-32/assentamento na Tabela 11.

TABELA 10 - MODELAGEM SARIMA JS-I-31/DESLIZAMENTO

Variável	Coefficiente	Erro padrão	Estatística-t	Probabilidade
AR(11)	0.225670	0.066736	3.381544	0.0009
AR(24)	0.251478	0.068522	3.670006	0.0003
AR(9)	0.141924	0.067231	2.111003	0.0360
MA(1)	0.517388	0.067210	7.698094	0.0000
MA(2)	0.314569	0.066491	4.731017	0.0000
MA(3)	0.390747	0.065099	6.002320	0.0000
MA(4)	0.179742	0.064230	2.798389	0.0056
MA(14)	0.232043	0.063724	3.641373	0.0003
MA(13)	0.280050	0.064866	4.317343	0.0000
MA(12)	0.253222	0.061985	4.085232	0.0001
R-quadrado	0.491974	Média da variável dependente		-19.40224
R-quadrado ajustado	0.469779	Desvio padrão da variável dependente		20.50964
Erro padrão da regressão	14.93436	Akaike		8.290397
Soma dos resíduos ao quadrados	45945.24	Schwarz		8.446660
Log likelihood	-885.3628	Hannan-Quinn		8.353527
Durbin-Watson	1.957135			

FONTE: O autor (2015).

TABELA 11 - MODELAGEM SARIMA JS-I-32/ASSENTAMENTO

Variável	Coefficiente	Erro padrão	Estatística-t	Probabilidade
AR(1)	0.448383	0.036321	12.34490	0.0000
AR(11)	0.563698	0.037088	15.19883	0.0000
MA(11)	-0.423345	0.077235	-5.481288	0.0000
MA(12)	-0.144185	0.062364	-2.311990	0.0217
R-quadrado	0.755362	Média da variável dependente		149.6874
R-quadrado ajustado	0.751916	Desvio padrão da variável dependente		24.43959
Erro padrão da regressão	12.17287	Akaike		7.854558
Soma dos resíduos ao quadrados	31562.08	Schwarz		7.916860
Log likelihood	-848.2195	Hannan-Quinn		7.879725
Durbin-Watson	2.037337			

FONTE: O autor (2015).

Etapa 2: Nesta etapa para cada uma das séries $(y_{js_31d}(t))_{t=1}^{252}$ e $(y_{js_32a}(t))_{t=1}^{252}$ foi realizada a decomposição ortogonal *Wavelet* de nível $r = 2$, considerando as bases *daubechies* (db 1,2,...,45), *coiflets* (coif 1,2,...,5), *symlets* (sym 1,2,...,30) e *biorthogonal* (1.1, 1.3, ..., 6.8), gerando um total de 285 subséries para a série $(y_{js_31d}(t))_{t=1}^{240}$ e 285 subséries para a série $(y_{js_32a}(t))_{t=1}^{240}$.

Etapa 3: Nesta etapa para as séries provenientes da decomposição *Wavelet* realizada na $(y_{js_31d}(t))_{t=1}^{240}$ e também na série $(y_{js_32a}(t))_{t=1}^{240}$ são obtidas as previsões via *Support Vector Regression* de Múltiplos Núcleos.

Na Tabela 12, são mostrados dois melhores resultados obtidos para cada família *Wavelet* e a estatística MSE da amostra de validação para a série $(y_{js_31d}(t))_{t=1}^{240}$ e na Tabela 13 para a série $(y_{js_32a}(t))_{t=1}^{240}$.

TABELA 12 - DOIS MELHORES RESULTADOS PARA CADA FAMÍLIA WAVELET (JS-I-31/DESLIZAMENTO)

Família	Base	Validação
		MSE
<i>Daubechies</i>	db16	103,8612
	db41	101,2402
<i>symlets</i>	sym12	097,9095
	sym16	101,5539
<i>Coiflets</i>	coif4	191,3216
	coif5	178,2128
<i>Biorthogonal</i>	Bior4.4	158,9289
	bior6.8	148,3924

FONTE: O autor (2015).

Da Tabela 12, observa-se que as modelagens escolhidas são aquelas que apresentaram a menor estatística de aderência MSE, para a série JS-I-31/deslizamento são as bases db41, sym12, coif5 e bior6.8.

TABELA 13 - DOIS MELHORES RESULTADOS PARA CADA FAMÍLIA WAVELET (JS-I-32/ASSENTAMENTO)

Família	Base	Validação
		MSE
<i>Daubechies</i>	db8	55,1855
	db27	54,7305
<i>Symlets</i>	sym2	40,2333
	sym21	47,1154
<i>Coiflets</i>	coif1	58,8126
	coif5	78,8863
<i>Biorthogonal</i>	bior2.8	48,6305
	bior5.5	46,6346

FONTE: O autor (2015).

Da Tabela 13, observa-se que as modelagens escolhidas são aquelas que apresentaram a menor estatística de aderência MSE, para a série JS-I-32/assentamento são as bases db27, sym2, coif1 e bior5.5.

Etapa 4: Nesta etapa foram combinadas para cada série as previsões das melhores modelagens obtidas quando comparada a estatística de aderência MSE no conjunto de validação referente a cada família *Wavelet*.

A combinação referente à série JS-I-31/deslizamento é representada por:

$$\left(\hat{y}_{js_31d}(t)\right)_{t=12}^{240} = \left[\begin{array}{l} \rho_1 \times \left(\hat{y}_{db41_js_31d}(t)\right) + \rho_2 \times \left(\hat{y}_{sym12_js_31d}(t)\right) + \\ \rho_3 \times \left(\hat{y}_{coif5_js_31d}(t)\right) + \rho_4 \times \left(\hat{y}_{bior3.8_js_31d}(t)\right) \end{array} \right]_{t=12}^{240}, \text{ onde as constantes}$$

adaptativas assumem os seguintes valores $\rho_1=0,122238$, $\rho_2=0,56804$, $\rho_3=0,753464$ e $\rho_4=-0,31029$, após a minimização do erro quadrático médio (MSE).

Já a combinação referente à série JS-I-32/assentamento é representada por:

$$\left(\hat{y}_{js_32a}(t)\right)_{t=12}^{240} = \left[\begin{array}{l} \rho_1 \times \left(\hat{y}_{db27_js_32a}(t)\right) + \rho_2 \times \left(\hat{y}_{sym2_js_32a}(t)\right) + \\ \rho_3 \times \left(\hat{y}_{coif1_js_32a}(t)\right) + \rho_4 \times \left(\hat{y}_{bior5.5_js_32a}(t)\right) \end{array} \right]_{t=12}^{240}, \text{ onde as constantes}$$

adaptativas assumem os seguintes valores $\rho_1=0,633148$, $\rho_2=0,085688$, $\rho_3=-0,02554$ e $\rho_4=0,308654$, após a minimização do erro quadrático médio (MSE).

São obtidas nesta etapa, as previsões do modelo SVR *Wavelet* de Múltiplos Núcleos para a série JS-I-31/deslizamento $\left(\hat{N}_{js_31d}(t)\right)_{t=12}^{240}$ e também para a série JS-I-32/assentamento $\left(\hat{N}_{js_32a}(t)\right)_{t=12}^{240}$ que representam a componente não linear do modelo híbrido proposto.

Etapa 5: Nesta etapa tomam-se as previsões obtidas pelo modelo linear (SARIMA) e do modelo não linear (SVRWMN) para ambas as séries JS-I-31/deslizamento e JS-I-32/assentamento. Representada respectivamente por $\left(\hat{L}_{js_31d}(t)\right)_{t=25}^{240+12}$, $\left(\hat{N}_{js_31d}(t)\right)_{t=12}^{240}$, $\left(\hat{L}_{js_32a}(t)\right)_{t=4}^{240+12}$ e $\left(\hat{N}_{js_32a}(t)\right)_{t=12}^{240}$. Faz-se a média, para a obtenção das previsões pontuais para cada t , para cada série.

Para série a JS-I-31/deslizamento e para a série JS-I-32/assentamento tem-se, respectivamente $\left(\hat{y}_{js_31d}(t)\right)_{t=25}^{240+12} = \frac{1}{2} \left(\hat{L}_{js_31d}(t) + \hat{N}_{js_31d}(t)\right)_{t=25}^{240+12}$ e


$$\left(\hat{y}_{js_32a}(t)\right)_{t=12}^{240+12} = \frac{1}{2} \left(\hat{L}_{js_32a}(t) + \hat{N}_{js_32a}(t)\right)_{t=12}^{240+12}.$$

O método híbrido SSVRWMN apresenta em sua estrutura de autodependência informações lineares e não lineares e pode ser considerado como uma versão filtrada da série temporal $y(t)$, tanto por um filtro linear (etapa 1) quanto por um filtro não linear (etapa 3 e 4).

Portanto, as listas $(\hat{y}_{js_31d}(t))_{t=25}^{240+12}$ e $(\hat{y}_{js_32a}(t))_{t=12}^{240+12}$ de previsões, dentro e fora da amostra (previsões *multi step*), consistem nos resultados do método SSVRWMN, para as séries das base de alongâmetro JS-I-31/deslizamento e para a série JS-I-32/assentamento.


O gráfico das previsões fora da amostra (dados de teste) pelo método híbrido proposto SSVRWMN para a série temporal $y_{js_31d}(t)$ está representado na Figura 18 e para a série $y_{js_32a}(t)$ na Figura 19.

FIGURA 18 - GRÁFICO DA SÉRIE JS-I-31/D E PREVISÕES PELO MÉTODO SSVRWMN.



FONTE: O autor (2015).

FIGURA 19 - GRÁFICO DA SÉRIE JS-I-32/A E PREVISÕES PELO MÉTODO SSVRWMN.



FONTE: O autor (2015).

Nesta etapa, é possível fazer a comparação das previsões do método proposto com as previsões obtidas pelos métodos SARIMA, SVR e SARIMA-SVR, referentes às estatísticas de aderência MSE, MAPE e MAE que são apresentadas na Tabela 14 para a série $y_{js_31d}(t)$ e na Tabela 15 para a série $y_{js_32a}(t)$.

TABELA 14 - COMPARATIVO MSE, MAPE E MAE PARA A SÉRIE JS-I-31/D *MULTI STEP* $h=12$

Método	MSE	MAPE	MAE
SARIMA	68,33407	47,6801%	7,4649
SVR	95,47216	36,1543%	7,0075
SARIMA-SVR	69,37517	48,4403%	7,5845
SSVRWMN	33,61030	24,3152%	4,8277

FONTE: O autor (2015).

Da Tabela 14, verifica-se que o método proposto SSVRWMN obteve nas previsões da série temporal do instrumento JS-I-31/deslizamento uma redução nas três estatísticas MSE, MAPE e MAE, em relação a todos os demais métodos preditivos listados. Comparando-o ao segundo melhor resultado (a saber, o método SARIMA), a redução relativa foi de, aproximadamente, 46% na medida MSE.

TABELA 15 - COMPARATIVO MSE, MAPE E MAE PARA A SÉRIE JS-I-32/A *MULTI STEP* $h=12$

Método	MSE	MAPE	MAE
SARIMA	260,0415	8,5258%	13,74783
SVR	232,7124	8,1150%	13,39976
SARIMA-SVR	238,5933	8,2530%	13,44831
SSVRWMN	207,0938	8,02975%	13,12771


FONTE: O autor (2015).

Da Tabela 15, verifica-se que o método proposto SSVRWMN obteve nas previsões da série temporal do instrumento JS-I-32/assentamento uma redução nas três estatísticas MSE, MAPE e MAE, em relação a todos os demais métodos preditivos listados. Comparando-o ao segundo melhor resultado (a saber, o método SVR), a redução relativa foi de, aproximadamente, 11% na medida MSE. Tais resultados demonstram a eficiência preditiva do método proposto diante de abordagens consagradas na literatura de séries temporais, como: SARIMA, SVR e o híbrido SARIMA-SVR.

ETAPA 6: Nesta etapa, para cada uma das séries temporais dos piezômetros foram obtidas as séries dos resíduos, representadas por $(r_{js_31d}(t))_{t=25}^{240} = (y_{js_31d}(t) - \hat{y}_{js_31d}(t))_{t=25}^{240}$ e $(r_{js_32a}(t))_{t=25}^{240} = (y_{js_32a}(t) - \hat{y}_{js_32a}(t))_{t=25}^{240}$, que são utilizadas no procedimento *Bootstrap* residual conforme seção 2.6, para geração de cenários e obtenção do intervalo de confiança.


A Figura 20 ilustra o intervalo de confiança obtido através do procedimento *Bootstrap* para a série JS-I-31/deslizamento e na Figura 21 o intervalo de confiança para a série JS-I-32/assentamento.

FIGURA 20 - INTERVALO DE CONFIANÇA PARA A SÉRIE TEMPORAL JS-I-31/DESLIZAMENTO



FONTE: O autor (2015).

FIGURA 21 - INTERVALO DE CONFIANÇA PARA A SÉRIE TEMPORAL JS-I-32/ASSENTAMENTO



FONTE: O autor (2015).

4.1.4 Extensômetros

Sejam as séries temporais provenientes do instrumento extensômetro EM-I-7-1, representada por $(y_{em7_1}(t))_{t=1}^{252}$ e outra proveniente do extensômetro EM-I-9-1 que será designada por $(y_{em9_1}(t))_{t=1}^{252}$, ambas de tamanho $T = 252$, sendo reservados $t = 1, 2, \dots, 240$ para ajuste do modelo. Seguindo as etapas do método SSVRWMN, tem-se:

Etapa 1: Para ambas as séries temporais provenientes dos extensômetros $(y_{em7_1}(t))_{t=1}^{252}$ e $(y_{em9_1}(t))_{t=1}^{252}$ foi realizada a modelagem através de um modelo SARIMA distinto, gerando as seguintes sequências de previsões, $(\hat{y}_{em7_1}(t))_{t=4}^{240+12}$ e $(\hat{y}_{em9_1}(t))_{t=12}^{240+12}$. Tais previsões são consideradas pelo método híbrido como a previsão da componente linear representada para cada série como $(\hat{L}_{em7_1}(t))_{t=12}^{240+12}$ e $(\hat{L}_{em9_1}(t))_{t=12}^{240+12}$.

Os valores encontrados na modelagem da série referente ao instrumento extensômetro EM-I-7-1 são apresentados na Tabela 16 e os referentes ao instrumento extensômetro EM-I-9-1 na Tabela 17.

TABELA 16 - MODELAGEM SARIMA EM-I-7-1

Variável	Coefficiente	Erro padrão	Estatística-t	Probabilidade
AR(1)	0.767367	0.035640	21.53120	0.0000
AR(8)	0.264256	0.039982	6.609414	0.0000
AR(18)	-0.220425	0.039471	-5.584478	0.0000
AR(24)	0.187073	0.035360	5.290584	0.0000
MA(2)	0.176284	0.070694	2.493623	0.0134
MA(4)	0.248729	0.070779	3.514168	0.0005
R-quadrado	0.911205	Média da variável dependente		-0.203009
R-quadrado ajustado	0.909091	Desvio padrão da variável dependente		0.065135
Erro padrão da regressão	0.019639	Akaike		-4.995234
Soma dos resíduos ao quadrados	0.080993	Schwarz		-4.901476
Log likelihood	545.4852	Hannan-Quinn		-4.957355
Durbin-Watson	1.988555			

FONTE: O autor (2015).

TABELA 17 - MODELAGEM SARIMA EM-I-9-1

Variável	Coefficiente	Erro padrão	Estatística-t	Probabilidade
AR(8)	-0.170767	0.065767	-2.596558	0.0101
AR(10)	0.193705	0.066151	2.928215	0.0038
SAR(12)	0.879812	0.041404	21.24940	0.0000
MA(1)	-0.637612	0.050954	-12.51347	0.0000
MA(13)	0.174263	0.050613	3.443013	0.0007
SMA(12)	-0.675231	0.074040	-9.119859	0.0000
R-quadrado	0.486061	Média da variável dependente		-0.000369
R-quadrado ajustado	0.473882	Desvio padrão da variável dependente		0.021275
Erro padrão da regressão	0.015432	Akaike		-5.477503
Soma dos resíduos ao quadrados	0.050248	Schwarz		-5.384050
Log likelihood	600.3091	Hannan-Quinn		-5.439752
Durbin-Watson	2.033248			

FONTE: O autor (2015).

Etapa 2: Nesta etapa para cada uma das séries temporais $(y_{em7-1}(t))_{t=1}^{240}$ e $(y_{em9-1}(t))_{t=1}^{240}$ foi realizada a decomposição ortogonal *Wavelet* de nível $r=2$, considerando as bases *daubechies* (db 1,2,...,45), *coiflets* (coif 1,2,...,5), *symlets* (sym 1,2,...,30) e *biorthogonal* (1.1, 1.3, ..., 6.8), gerando um total de 285 subséries para a série $(y_{em7-1}(t))_{t=1}^{240}$ e 285 subséries para a série $(y_{em9-1}(t))_{t=1}^{240}$.

Etapa 3: Nesta etapa para as séries provenientes da decomposição *Wavelet* realizada na $(y_{em7-1}(t))_{t=1}^{240}$ e também na série $(y_{em9-1}(t))_{t=1}^{240}$ são obtidas as previsões via *Support Vector Regression* de Múltiplos Núcleos.

Na Tabela 18 são mostrados os dois melhores resultados obtidos para cada família *Wavelet* referente a estatística MSE da amostra de validação para a série $(y_{em7-1}(t))_{t=1}^{240}$ e na Tabela 19 para a série $(y_{em9-1}(t))_{t=1}^{240}$.

TABELA 18 - DOIS MELHORES RESULTADOS PARA CADA FAMÍLIA WAVELET (EM-I-7-1)

Família	Base	Validação
		MSE
<i>Daubechies</i>	db6	0,0000522
	db40	0,0000545
<i>Symlets</i>	sym22	0,0000875
	sym26	0,0000974
<i>Coiflets</i>	coif4	0,0001904
	coif3	0,0001958
<i>Biorthogonal</i>	bior4.4	0,0000773
	bior6.8	0,0000914

FONTE: O autor (2015).

Na Tabela 18 são mostrados os dois melhores resultados obtidos para cada família *Wavelet* referente à estatística MSE da amostra de validação para a série $(y_{em7-1}(t))_{t=1}^{240}$ e na Tabela 19 para a série $(y_{em9-1}(t))_{t=1}^{240}$.

TABELA 19 - DOIS MELHORES RESULTADOS PARA CADA FAMÍLIA WAVELET (EM-I-9-1)

Família	Base	Validação
		MSE
<i>Daubechies</i>	db22	0,0001080
	db44	0,0000984
<i>Symlets</i>	sym8	0,0001155
	sym29	0,0001143
<i>Coiflets</i>	coif2	0,0001180
	coif3	0,0001150
<i>Biorthogonal</i>	bior2.6	0,0001149
	bior2.8	0,0001147

FONTE: O autor (2015).

Da Tabela 19, observa-se que as modelagens escolhidas são aquelas que apresentaram a menor estatística MSE, para a série EM-I-9-1 são as bases db44, sym29, coif3 e bior2.8.

Etapas 4: Nesta etapa foram combinadas para cada série as previsões das melhores modelagens obtidas quando comparada a estatística de aderência MSE no conjunto de validação referente a cada família *Wavelet*.

A combinação referente à série EM-I-7-1 é representada por:

$$(\hat{y}_{em7-1}(t))_{t=12}^{240} = \left[\begin{array}{l} \rho_1 \times (\hat{y}_{db6-em7-1}(t)) + \rho_2 \times (\hat{y}_{sym22-em7-1}(t)) + \\ \rho_3 \times (\hat{y}_{coif4-em7-1}(t)) + \rho_4 \times (\hat{y}_{bior4.4-em7-1}(t)) \end{array} \right]_{t=12}^{240}, \text{ onde as constantes}$$

adaptativas assumem os seguintes valores $\rho_1=1,264955$, $\rho_2=0,419522$, $\rho_3=-0,59129$ e $\rho_4=-0,11061$, após a minimização do erro quadrático médio (MSE).

Já a combinação referente à série EM-I-9-1 é representada por:

$$\left(\hat{y}_{em9_1}(t)\right)_{t=12}^{240} = \left[\begin{array}{l} \rho_1 \times \left(\hat{y}_{db44_em9_1}(t)\right) + \rho_2 \times \left(\hat{y}_{sym29_em9_1}(t)\right) + \\ \rho_3 \times \left(\hat{y}_{coif3_em9_1}(t)\right) + \rho_4 \times \left(\hat{y}_{bior2.8_em9_1}(t)\right) \end{array} \right]_{t=12}^{240}, \text{ onde as constantes}$$

adaptativas assumem os seguintes valores $\rho_1=1,889358$, $\rho_2=0,000162$, $\rho_3=-0,54076$ e $\rho_4=-0,34884$, após a minimização do erro quadrático médio (MSE).

São obtidas nesta etapa, as previsões do modelo SVR *Wavelet* Múltiplos Núcleos para a série EM-I-7-1 $\left(\hat{N}_{em7_1}(t)\right)_{t=12}^{240}$ e também para a série EM-I-9-1 $\left(\hat{N}_{em9_1}(t)\right)_{t=12}^{240}$ que são as componentes não lineares do modelo híbrido proposto.


Etapa 5: Nesta etapa tomam-se as previsões obtidas pelo modelo linear (SARIMA) e do modelo não linear (SVRWMN) de ambas as séries EM-I-7-1 e EM-I-9-1 que representamos respectivamente por $\left(\hat{L}_{em7_1}(t)\right)_{t=12}^{240+12}$ e $\left(\hat{L}_{em9_1}(t)\right)_{t=12}^{240+12}$ para o caso linear e por $\left(\hat{N}_{em9_1}(t)\right)_{t=12}^{240}$ e $\left(\hat{N}_{em9_1}(t)\right)_{t=12}^{240}$ para o caso não linear.

Faz-se a média, para a obtenção das previsões pontuais para cada t , em cada série. Para a série EM-I-7-1 tem-se $\left(\hat{y}_{em7_1}(t)\right)_{t=12}^{240+12} = \frac{1}{2} \left(\hat{L}_{em7_1}(t) + \hat{N}_{em7_1}(t)\right)_{t=12}^{240+12}$ e para a série EM-I-9-1 tem-se: $\left(\hat{y}_{em9_1}(t)\right)_{t=12}^{240+12} = \frac{1}{2} \left(\hat{L}_{em9_1}(t) + \hat{N}_{em9_1}(t)\right)_{t=12}^{240+12}$.

O método híbrido SSVRWMN apresenta em sua estrutura de autodependência informações lineares e não lineares e pode ser considerado como uma versão filtrada da série temporal $y(t)$, tanto por um filtro linear (etapa 1) quanto por um filtro não linear (etapa 3 e 4). Portanto, as listas $\left(\hat{y}_{em7_1}(t)\right)_{t=12}^{240+12}$ e $\left(\hat{y}_{em9_1}(t)\right)_{t=12}^{240+12}$ de previsões, dentro e fora da amostra (previsões *multi step*), consistem nos resultados do método SSVRWMN, para as séries dos extensômetros EM-I-7-1 e para a série EM-I-9-1.


O gráfico das previsões fora da amostra (dados de teste) pelo método híbrido proposto SSVRWMN para a série temporal $y_{em7_1}(t)$ está representado na Figura 22 e para a série $y_{em9_1}(t)$ na Figura 23.

FIGURA 22 - GRÁFICO DA SÉRIE EM-I-7-1 E PREVISÕES PELO MÉTODO SSVRWMN.



FONTE: O autor (2015).

FIGURA 23 - GRÁFICO DA SÉRIE EM-I-9-1 E PREVISÕES PELO MÉTODO SSVRWMN.



FONTE: O autor (2015).

Nesta etapa, é possível fazer a comparação das previsões do método proposto com as previsões obtidas pelos métodos SARIMA, SVR e SARIMA-SVR, referentes às estatísticas MSE, MAPE e MAE que são apresentadas na Tabela 20 para a série $y_{em7_1}(t)$ e na Tabela 15 para a série $y_{em9_1}(t)$.

TABELA 20 - COMPARATIVO MSE, MAPE E MAE PARA A SÉRIE EM-I-7-1 *MULTI STEP* $h=12$

Método	MSE	MAPE	MAE
SARIMA	0,000243	5,638%	0,0129
SVR	0,000594	8,398%	0,0209
SARIMA-SVR	0,000286	5,682%	0,0135
SSVRWMN	0,000226	5,546%	0,0119

FONTE: O autor (2015).

Da Tabela 20, verifica-se que o método proposto SSVRWMN obteve nas previsões da série temporal do instrumento EM-I-7-1 uma redução nas três estatísticas MSE, MAPE e MAE, em relação a todos os demais métodos preditivos listados. Comparando-o ao segundo melhor resultado (a saber, o método SARIMA), a redução relativa foi de, aproximadamente, 7% na medida MSE.

TABELA 21 - COMPARATIVO MSE, MAPE E MAE PARA A SÉRIE EM-I-9-1 *MULTI STEP* $h=12$

Método	MSE	MAPE	MAE
SARIMA	0,000722	2,9392%	0,02546
SVR	0,000876	3,1855%	0,02751
SARIMA-SVR	0,000751	2,8291%	0,02454
SSVRWMN	0,000522	2,4418%	0,02107

FONTE: O autor (2015).


Da Tabela 21, verifica-se que o método proposto SSVRWMN obteve nas previsões da série temporal do instrumento EM-I-9-1 uma redução nas três estatísticas MSE, MAPE e MAE, em relação a todos os demais métodos preditivos listados. Comparando-o ao segundo melhor resultado (a saber, o método SARIMA), a redução relativa foi de, aproximadamente, 28% na medida MSE.

Tais resultados demonstram a eficiência preditiva do método proposto diante de abordagens consagradas na literatura de séries temporais, como: SARIMA, SVR e o híbrido SARIMA-SVR.

ETAPA 6: Nesta etapa, para cada uma das séries temporais dos extensômetros foram obtidas as séries dos resíduos, representadas por $\left(r_{em7_1}(t)\right)_{t=12}^{240} = \left(y_{em7_1}(t) - \hat{y}_{em7_1}(t)\right)_{t=12}^{240}$ e $\left(r_{em9_1}(t)\right)_{t=12}^{240} = \left(y_{em9_1}(t) - \hat{y}_{em9_1}(t)\right)_{t=12}^{240}$, que são utilizadas no procedimento *Bootstrap* residual conforme seção 2.6, para geração de cenários e obtenção do intervalo de confiança.


A Figura 24 ilustra o intervalo de confiança obtido através do procedimento *Bootstrap* para a série EM-I-7-1 e na Figura 25 o intervalo de confiança obtido para a série EM-I-9-1.

FIGURA 24 - INTERVALO DE CONFIANÇA PARA A SÉRIE TEMPORAL EM-I-7-1



FONTE: O autor (2015).

FIGURA 25 - INTERVALO DE CONFIANÇA PARA A SÉRIE TEMPORAL EM-I-9-1



FONTE: O autor (2015).

5 CONCLUSÃO E CONSIDERAÇÕES FINAIS

O presente trabalho apresentou um método de previsão de séries temporais aplicado a séries temporais provenientes da aferição de instrumentos instalados no bloco I10 da barragem da Usina Hidrelétrica de Itaipu, que monitoram o tombamento do referido bloco sentido montante-jusante. O método é denominado de método híbrido SARIMA *Support Vector Regression Wavelet* de Múltiplos Núcleos, (SSVRWMN).

Em relação ao método proposto, que tem como finalidade captar estruturas de autodependência linear e não linear, é importante destacar alguns pontos.

A escolha da modelagem SARIMA, (BOX *et al.* 2008) tem como objetivo capturar as estruturas de autodependência linear, considerando o efeito sazonal.

O uso de *Wavelet* detecta o comportamento de uma série temporal em altas e baixas frequências (TEIXEIRA JR. *et al.* 2015), com o intuito de reduzir possíveis ruídos existentes na série original (o que significa que a componente *Wavelet* sempre apresenta padrão de comportamento mais regular para fins de modelagem). Para a escolha das melhores bases ortonormais *Wavelet*, para cada série temporal, foi realizada a modelagem via *Support Vector Regression* que combina Múltiplos Núcleos para as bases provenientes da família *daubechies* de ordens (1, ..., 45), *coiflets* de ordens (1, ..., 5), *symlets* de ordens (1, ..., 30) e *biorthogonal* de ordens (1.1, 1.3, ..., 6.8) (DAUBECHIES, 1992), sendo selecionada para combinação uma modelagem de cada família *Wavelet*, por meio dos resultados obtidos nos experimentos realizados que apresentaram melhor desempenho entre os sinais da amostra de treino inicial e os respectivos sinais *Wavelet* gerados em decorrência da soma das componentes de aproximação e de detalhe.

No que tange à utilização do *Support Vector Regression* (SVR), sua escolha deve-se ao fato de ser uma abordagem eficiente na modelagem de séries temporais oriundas de processos que apresentam estruturas de autodependência não lineares (CHEN *et al.* 2015). O processo de formação do modelo SVR utiliza a programação quadrática com restrições lineares que fornece um único valor ótimo não havendo problemas de mínimos locais. Sua solução é esparsa, uma vez que apenas os dados essenciais são utilizados para resolver a função de regressão. O modelo produzido

por SVR depende apenas de um subconjunto de dados de formação e por sua função de custo utilizada para a construção do modelo (SMOLA e SCHÖLKOPF, 1998).

Em síntese, no processo de geração de previsões, o método proposto SSVRWMN gerou previsões substancialmente melhores que as obtidas pelos métodos preditivos SARIMA e SVR individualmente, e o composto SARIMA-SVR, em todas as estatísticas de aderência consideradas no presente trabalho. Portanto, as previsões provenientes do método SSVRWMN veem agregar informações, contribuindo desta forma com a tomada de decisão, no que se refere ao problema estudado.

O método SSVRWMN se mostrou uma alternativa factível e eficiente à modelagem de séries temporais (advindas de acontecimentos reais), dadas a sua abrangência e a sua eficiência mostrada nas pesquisas. Tais resultados são motivadores da aplicação do método para séries temporais de outras áreas, mesmo que a base teórica do método híbrido proposto é matematicamente complexa, o uso dos softwares e rotinas computacionais referenciados no texto permite a sua utilização.

Objetivando um aprimoramento dos resultados obtidos nesta tese, são propostas algumas sugestões para trabalhos futuros:

- a) Empregar na série temporal, antes de sua modelagem, uma filtragem estatística, com o objetivo de extrair possíveis ruídos. Podem-se utilizar, por exemplo, as filtrações *Wavelet* (DONOHO *et al.* 1995) ou *Singular Spectrum Analysis* (SSA) (ELSNER e TSONIS, 1996);
- b) Usar a combinação não linear (BERTSEKAS, 1999) nas previsões obtidas pelo método SVRWMN;
- c) Utilizar uma variação maior de núcleos (TAYLOR e CRISTIANINI, 2004), no que tange à modelagem SVR;
- d) Otimizar a busca dos parâmetros SVR através de meta-heurísticas, como por exemplo, *Particle Swarm Optimization* (PSO) (KENNEDY e EBERHART, 1997), para evitar problemas de *overfitting* e *underfitting* (TAYLOR e CRISTIANINI, 2004);
- e) Implementar parâmetros adaptáveis no modelo SVR com o intuito de alocar um maior peso nos vetores-suporte mais recentes e menor peso nos dados de treino mais distantes.

REFERÊNCIAS

AGRAWAL, R.; IMIELIŃSKI, T.; SWAMI, A. Mining association rules between sets of items in large databases. **ACM SIGMOD Record**, v. 22, n. 2, p. 207–216, 1993. ACM. Disponível em: <<http://dl.acm.org/citation.cfm?id=170036.170072>>. Acesso em: 12/1/2015.

ALADAG, C. H.; EGRIOGLU, E.; KADILAR, C. Forecasting nonlinear time series with a hybrid methodology. **Applied Mathematics Letters**, v. 22, n. 9, p. 1467–1470, 2009. Elsevier Ltd. Disponível em: <<http://dx.doi.org/10.1016/j.aml.2009.02.006>>. .

ALTAMEEM, T. A.; NIKOLIĆ, V.; SHAMSHIRBAND, S.; et al. Potential of support vector regression for optimization of lens system. **Computer-Aided Design**, v. 62, p. 57–63, 2015. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0010448514002322>>. Acesso em: 28/1/2015.

ALWEE, R.; HJ SHAMSUDDIN, S. M.; SALLEHUDDIN, R. Hybrid support vector regression and autoregressive integrated moving average models improved by particle swarm optimization for property crime rates forecasting with economic indicators. **The Scientific World Journal**, v. 2013, 2013.

ANANDHI, V.; CHEZIAN, R. M. SUPPORT VECTOR REGRESSION IN FORECASTING. **International Journal of Advanced Research in Computer and Communication Engineering**, v. 2, n. 10, p. 4128–4151, 2013.

AQUINO, R. R. B. DE; LIRA, M. M. S.; DE OLIVEIRA, J. B.; et al. Application of wavelet and neural network models for wind speed and power generation forecasting in a Brazilian experimental wind park. 2009 International Joint Conference on Neural Networks. **Anais...** . p.172–178, 2009. IEEE. Disponível em: <<http://ieeexplore.ieee.org/articleDetails.jsp?arnumber=5178791>>. Acesso em: 4/3/2015.

AREEKUL, P.; SENJYU, T.; TOYAMA, H.; YONA, A. A hybrid ARIMA and neural network model for short-term price forecasting in deregulated market. **IEEE Transactions on Power Systems**, v. 25, n. 1, p. 524–530, 2010.

ARMSTRONG, J. S. **PRINCIPLES OF FORECASTING: A Handbook for Researchers and Practitioners**. Pennsylvania USA: Kluwer Academic Publishers, 2001.

BABAI, M. Z.; ALI, M. M.; BOYLAN, J. E.; SYNTETOS, A. A. Forecasting and inventory performance in a two-stage supply chain with ARIMA(0,1,1) demand:

Theory and empirical analysis. **International Journal of Production Economics**, v. 143, n. 2, p. 463–471, 2013. Elsevier. Disponível em: <<http://dx.doi.org/10.1016/j.ijpe.2011.09.004>>. .

BABU, C. N.; REDDY, B. E. A moving-average filter based hybrid ARIMA–ANN model for forecasting time series data. **Applied Soft Computing**, v. 23, p. 27–38, 2014. Elsevier B.V. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1568494614002555>>. .

BATES, J. M.; GRANGER, C. W. J. The Combination of Forecasts. **Journal of the Operational Research Society**, 1969.

BAYDAROĞLU, Ö.; KOÇAK, K. SVR-based prediction of evaporation combined with chaotic approach. **Journal of Hydrology**, v. 508, p. 356–363, 2014. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S002216941300824X>>. Acesso em: 28/1/2015.

BELTRAMI, M.; LOCH, G. V.; SILVA, A. C. L. DA. COMPARAÇÃO DAS TÉCNICAS DE SUPPORT VECTOR REGRESSION E REDES NEURAIS NA PRECIFICAÇÃO DE OPÇÕES. **Xliisbpo**, p. 572–583, 2010.

BERTSEKAS, D. **Nonlinear Programming**. Athena Scientific, 1999.

BILLIO, M.; CASARIN, R.; RAVAZZOLO, F.; VAN DIJK, H. K. Time-varying combinations of predictive densities using nonlinear filtering. **Journal of Econometrics**, v. 177, n. 2, p. 213–232, 2013. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0304407613000869>>. Acesso em: 27/1/2015.

BOSER, B. E.; GUYON, I. M.; VAPNIK, V. N. A training algorithm for optimal margin classifiers. Proceedings of the fifth annual workshop on Computational learning theory - COLT '92. **Anais...** p.144–152, 1992. New York, New York, USA: ACM Press. Disponível em: <<http://dl.acm.org/citation.cfm?id=130385.130401>>. Acesso em: 11/8/2014.

BOX, G.; JENKINS, G. **Time Series Analysis: Forecasting and Control**. San Francisco: Holden-Day, 1970.

BOX, G.; JENKINS, G.; REINSEL, G. **Time Series Analysis: Forecasting and Control**. 2008.

BUZZI, M. F. **Avaliação das correlações de séries temporais de leituras de instrumentos de monitoração geotécnico- estrutural e variáveis ambientais em**

barragens estudo de caso de itaipu, 2007. Universidade Federal do Paraná.

CHANG, C.-C.; LIN, C.-J. LIBSVM -- A Library for Support Vector Machines. Disponível em: <<http://www.csie.ntu.edu.tw/~cjlin/libsvm/>>. Acesso em: 2/1/2015.

CHEN, R.; LIANG, C.-Y.; HONG, W.-C.; GU, D.-X. Forecasting holiday daily tourist flow based on seasonal support vector regression with adaptive genetic algorithm. **Applied Soft Computing**, v. 26, p. 435–443, 2015. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1568494614005328>>. Acesso em: 27/1/2015.

CHENG, Y.; HU, J. Nonlinear system identification based on SVR with quasi-linear kernel. WCCI 2012 IEEE World Congress on Computational Intelligence. **Anais...**, 2012. World Congress on Computational Intelligence June, 10-15, 2012 - Brisbane, Australia: IEEE.

CLEMEN, R. T. Combining forecasts: A review and annotated bibliography. **International Journal of Forecasting**, 1989.

COHEN, A.; DAUBECHIES, I.; FEAUVEAU, J. C. Biorthogonal bases of compactly supported wavelets. (M Farge It Et Al, Org.) **Communications on Pure and Applied Mathematics**, v. 45, n. 5, p. 485–560, 1992. Disponível em: <<http://dx.doi.org/10.1002/cpa.3160450502>>. .

CORTES, C.; VAPNIK, V. Support-Vector Networks. **Machine Learning**, v. 20, n. 3, p. 273–297, 1995. Kluwer Academic Publishers. Disponível em: <<http://dl.acm.org/citation.cfm?id=218919.218929>>. Acesso em: 4/2/2015.

CRESPO, R. G.; ESCOBAR, R. F.; AGUILAR, L. J.; VELAZCO, S.; SANZ, A. G. C. Use of ARIMA mathematical analysis to model the implementation of expert system courses by means of free software OpenSim and Sloodle platforms in virtual university campuses. **Expert Systems with Applications**, v. 40, p. 7381–7390, 2013.

DAUBECHIES, I. Orthonormal bases of compactly supported wavelets. **Communications on Pure and Applied Mathematics**, v. 41, n. 7, p. 909–996, 1988. Disponível em: <<http://doi.wiley.com/10.1002/cpa.3160410705>>. Acesso em: 12/1/2015.

DAUBECHIES, I. The wavelet transform, time-frequency localization and signal analysis. **IEEE Transactions on Information Theory**, v. 36, n. 5, p. 961–1005, 1990. IEEE. Disponível em: <<http://ieeexplore.ieee.org/articleDetails.jsp?arnumber=57199>>. Acesso em: 13/1/2015.

DAUBECHIES, I. **Ten Lectures on Wavelets**. 1992a.

DAUBECHIES, I. **Ten lectures on wavelets**. Society for Industrial and Applied Mathematics, 1992b.

DAVISON, A. C.; HINKLEY, D. V. **Bootstrap Methods and their Application**. New York: Cambridge University Press, 1997.

DONOHU, D. L.; JOHNSTONE, I. M.; KERKYACHARIAN, G.; PICARD, D. Wavelet shrinkage: asymptopia. **Journal Royal Statistical Society**, v. 57, p. 301–369, 1995. Disponível em: <<http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.162.1643>>. Acesso em: 5/3/2015.

DONOHU, D. L.; JOHNSTONE, J. M. Ideal spatial adaptation by wavelet shrinkage. **Biometrika**, v. 81, n. 3, p. 425–455, 1994.

EFRON, B. Bootstrap Methods: Another Look at the Jackknife. **The Annals of Statistics**, v. 7, n. 1, p. 1–26, 1979. Institute of Mathematical Statistics. Disponível em: <<http://projecteuclid.org/euclid.aos/1176344552>>. Acesso em: 10/2/2015.

EFRON, B.; TIBSHIRANI, R. J. **An Introduction to the Bootstrap**. CRC Press, 1994.

EHLERS, R. S. **Análise de séries temporais**. 2009.

ELSNER, J. B.; TSONIS, A. A. **Singular Spectrum Analysis: A New Tool in Time Series Analysis**. 1996.

EVANS, M. K. **PRACTICAL BUSINESS FORECASTING**. Blackwell, 2003.

FARIA, A. E.; MUBWANDARIKWA, E. The geometric combination of bayesian forecasting models. **Journal of Forecasting**, v. 27, n. 1, p. 519–535, 2008.

FARUK, D. Ö. A hybrid neural network and ARIMA model for water quality time series prediction. **Engineering Applications of Artificial Intelligence**, v. 23, n. 4, p. 586–594, 2010.

GRANGER, C. W. J.; RAMANATHAN, R. Improved methods of combining forecasts. **Journal of Forecasting**, v. 3, n. 2, p. 197–204, 1984. Disponível em: <<http://doi.wiley.com/10.1002/for.3980030207>>. Acesso em: 6/2/2015.

GUPTA, S.; WILTON, P. C. Combination of Forecasts: An Extension. **Management Science**, 1987.

GUTIERREZ, C. E. C. **ELIMINAÇÃO DO RUÍDO POR ENCOLHIMENTO DE WAVELETS Uma aplicação à série de Preço Spot de Energia Elétrica do Brasil**, 2002. PUC-Rio.

HAAR, A. Zur Theorie der orthogonalen Funktionensysteme. **Mathematische Annalen**, v. 69, n. 3, p. 331–371, 1910. Disponível em: <<http://link.springer.com/10.1007/BF01456326>>. Acesso em: 17/2/2015.

HAAR, A. Zur Theorie der orthogonalen Funktionensysteme. **Mathematische Annalen**, v. 71, n. 1, p. 38–53, 1911. Springer-Verlag.

HAMILTON, J. D. **Time Series Analysis**. Princeton University Press, 1994.

HASSAN, J. ARIMA and regression models for prediction of daily and monthly clearness index. **Renewable Energy**, v. 68, p. 421–427, 2014. Elsevier Ltd. Disponível em: <<http://dx.doi.org/10.1016/j.renene.2014.02.016>>. .

HAYKIN, S. **Neural networks and learning machines**. 3rd ed. ed. 2009.

HE, W.; WANG, Z.; JIANG, H. Model optimizing and feature selecting for support vector regression in time series forecasting. **Neurocomputing**, v. 72, n. 1-3, p. 600–611, 2008. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0925231207003840>>. Acesso em: 28/1/2015.

HE, Z.; WEN, X.; LIU, H.; DU, J. A comparative study of artificial neural network, adaptive neuro fuzzy inference system and support vector machine for forecasting river flow in the semiarid mountain region. **Journal of Hydrology**, v. 509, p. 379–386, 2014. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0022169413008780>>. Acesso em: 7/3/2015.

HESKES, T. Practical confidence and prediction intervals. **Advances in neural information processing systems**, v. 9, p. 466–472, 1997.

HOLLAUER, G.; ISSLER, J. V.; NOTINI, H. H. Novo indicador coincidente para a atividade industrial brasileira. **Economia Aplicada**, v. 13, n. 1, p. 5–28, 2009. Economia Aplicada. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1413-80502009000100001&lng=en&nrm=iso&tlng=pt>. Acesso em: 6/2/2015.

HONG, W.-C. Electric load forecasting by seasonal recurrent SVR (support vector regression) with chaotic artificial bee colony algorithm. **Energy**, v. 36, n. 9, p. 5568–5578, 2011. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0360544211004634>>. Acesso em: 7/3/2015.

ITAIPU: USINA HIDRELÉTRICA. **Projeto: Aspectos de Engenharia**". Foz do Iguaçu - Pr, 2009.

KAO, L.-J.; CHIU, C.-C.; LU, C.-J.; YANG, J.-L. Integration of nonlinear independent component analysis and support vector regression for stock price forecasting. **Neurocomputing**, v. 99, p. 534–542, 2013. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0925231212006066>>. Acesso em: 8/1/2015.

KENNEDY, J.; EBERHART, R. C. A discrete binary version of the particle swarm algorithm. 1997 IEEE International Conference on Systems, Man, and Cybernetics. Computational Cybernetics and Simulation. **Anais...** v. 5, p.4104–4108, 1997. IEEE. Disponível em: <<http://ieeexplore.ieee.org/articleDetails.jsp?arnumber=637339>>. Acesso em: 13/1/2016.

KHASHEI, M.; BIJARI, M. An artificial neural network (p, d, q) model for timeseries forecasting. **Expert Systems with Applications**, v. 37, n. 1, p. 479–489, 2010. Elsevier Ltd. Disponível em: <<http://dx.doi.org/10.1016/j.eswa.2009.05.044>>. .

KHASHEI, M.; BIJARI, M. A new hybrid methodology for nonlinear time series forecasting. **Modelling and Simulation in Engineering**, v. 2011, 2011.

KHOSRAVI, A.; NAHAVANDI, S.; SRINIVASAN, D.; KHOSRAVI, R. Constructing Optimal Prediction Intervals by Using Neural Networks and Bootstrap Method. **IEEE transactions on neural networks and learning systems**, 2014. IEEE. Disponível em: <<http://ieeexplore.ieee.org/articleDetails.jsp?arnumber=6895153>>. Acesso em: 21/6/2015.

KISI, O.; CIMEN, M. A wavelet-support vector machine conjunction model for monthly streamflow forecasting. **Journal of Hydrology**, v. 399, n. 1-2, p. 132–140, 2011. Elsevier B.V. Disponível em: <<http://dx.doi.org/10.1016/j.jhydrol.2010.12.041>>. .

KUBRUSLY, C. S. **The Elements of Operator Theory**. Second Edi ed. New York, 2011.

KUBRUSLY, C. S.; LEVAN, N. Abstract wavelets generated by Hilbert space shift

operators. **Advances in mathematical and applications**, v. 16, p. 643–660, 2006.

KUBRUSLY, C. S.; LEVAN, N. Orthogonal decompositions for wavelets. **Applied Mathematics Letters**, v. 22, n. 8, p. 1286–1291, 2009. Elsevier Ltd. Disponível em: <<http://dx.doi.org/10.1016/j.aml.2009.01.044>>. .

LIU, H.; TIAN, H.-Q.; PAN, D.-F.; LI, Y.-F. Forecasting models for wind speed using wavelet, wavelet packet, time series and Artificial Neural Networks. **Applied Energy**, v. 107, p. 191–208, 2013. Elsevier Ltd. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0306261913001104>>. .

LU, C.-J. Sales forecasting of computer products based on variable selection scheme and support vector regression. **Neurocomputing**, v. 128, p. 491–499, 2014. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0925231213008850>>. Acesso em: 9/12/2014.

MAHESWARAN, R.; KHOSA, R. Wavelet Volterra Coupled Models for forecasting of nonlinear and non-stationary time series. **Neurocomputing**, v. 149, p. 1074–1084, 2015. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0925231214009643>>. Acesso em: 28/1/2015.

MAKRIDAKIS, S.; WINKLER, R. L. Averages of Forecasts: Some Empirical Results. **Management Science**, v. 29, n. 9, p. 987–996, 1983. INFORMS. Disponível em: <<http://pubsonline.informs.org/doi/abs/10.1287/mnsc.29.9.987?journalCode=mnsc>>. Acesso em: 28/2/2015.

MALLAT, S. **A Wavelet Tour of Signal Processing: The Sparse Way**. Third Edition. 2009.

MALLAT, S. G. Theory for multiresolution signal decomposition: the wavelet representation. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 11, n. 7, p. 674–693, 1989.

MANCUSO, A. C. B.; WERNER, L. Review of Combining Forecasts Approaches. **Independent Journal of Management & Production**, v. 4, n. June, p. 248–277, 2013. Disponível em: <<http://www.ijmp.jor.br/index.php/ijmp/article/view/59>>. .

MARQUARDT, D. W. An Algorithm for Least-Squares Estimation of Nonlinear Parameters. **Journal of the Society for Industrial and Applied Mathematics**, v. 11, n. 2, p. 431–441, 1963. Society for Industrial and Applied Mathematics. Disponível em: <<http://epubs.siam.org/doi/abs/10.1137/0111030?journalCode=smjmap.1>>. Acesso

em: 5/11/2014.

MATOS, SI. F. **Avaliação de instrumentos para auscultação de barragem de concreto. estudo de caso: deformímetros e tensômetros para concreto na barragem de itaipuUFPR**, 2002. Universidade Federal do Paraná.

MEYER, Y. **Wavelets-algorithms and applications**. 1993.

MOHAMMADI, K.; SHAMSHIRBAND, S.; TONG, C. W.; et al. A new hybrid support vector machine–wavelet transform approach for estimation of horizontal global solar radiation. **Energy Conversion and Management**, v. 92, p. 162–171, 2015.

Disponível em:

<<http://www.sciencedirect.com/science/article/pii/S0196890414010899>>. Acesso em: 10/1/2015.

MONTGOMERY, D. C.; RUNGER, G. C. **Estatística aplicada e probabilidade para engenheiros**. 2 ed ed. Rio de Janeiro: LTC, 2003.

MORETTIN, P. A.; TOLOI, C. M. DE C. **Análise de séries temporais**. Edgard Blucher, 2006.

MORLET, J. Sampling Theory and Wave Propagation. (C. H. Chen, Org.) **Issues in Acoustic Signal — Image Processing and Recognition NATO ASI Series Volume 1**, p. 233–261, 1983. Berlin, Heidelberg: Springer Berlin Heidelberg.

Disponível em: <<http://www.springerlink.com/index/10.1007/978-3-642-82002-1>>.

Acesso em: 26/2/2015.

ORTEGA, L.; KHASHANAH, K. A neuro-wavelet model for the short-term forecasting of high-frequency time series of stock returns. **Journal of Forecasting**, v. 33, n. July 2013, p. 134–146, 2014.

OSAKO, C. I. **A manutenção dos drenos nas Fundações de Barragens o caso da Usina Hidrelétrica de Itaipu**, 2002. Dissertação Curso de Pós-Graduação em Construção Civil, Universidade Federal do Paraná.

PAI, P.-F.; LIN, C.-S. A hybrid ARIMA and support vector machines model in stock price forecasting. **Omega**, 2005.

PAN, L.; POLITIS, D. N. Bootstrap prediction intervals for linear, nonlinear and nonparametric autoregressions. **Journal of Statistical Planning and Inference**, 2014. Disponível em:

<<http://www.sciencedirect.com/science/article/pii/S037837581400175X>>. Acesso em: 10/2/2015.

PANKRATZ, A. **Forecasting with Univariate Box - Jenkins Models: Concepts and Cases**. John Wiley & Sons, 2009.

PIRI, J.; SHAMSHIRBAND, S.; PETKOVIĆ, D.; TONG, C. W.; REHMAN, M. H. UR. Prediction of the solar radiation on the Earth using support vector regression technique. **Infrared Physics & Technology**, v. 68, p. 179–185, 2015. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1350449514002746>>. Acesso em: 28/1/2015.

REID, D. J. Combining three estimates of gross domestic product. **Economica**, v. 35, p. 431–444, 1968.

RODRIGUES, S. B.; SILVA, A. C. L. DA; TEIXEIRA, L. L.; et al. Forecasting of the relative displacements in block I11 of the Itaipu hydroelectric plant dam through a ARIMA-SVR hybrid approach. **Espaço Energia**, v. 22, n. 22, p. 28–37, 2015.

SANG, Y.-F. A review on the applications of wavelet transform in hydrology time series analysis. **Atmospheric Research**, v. 122, p. 8–15, 2013. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0169809512003924>>. Acesso em: 28/1/2015.

SCHÖLKOPF, B. **Support Vector Learning**, 1997. Oldenburg-Verlag.

SEO, Y.; KIM, S.; KISI, O.; SINGH, V. P. Daily water level forecasting using wavelet decomposition and artificial intelligence techniques. **Journal of Hydrology**, v. 520, p. 224–243, 2015. Elsevier B.V. Disponível em: <<http://dx.doi.org/10.1016/j.jhydrol.2014.11.050>>. .

SHI, H.; ZHANG, X.; SU, X.; CHEN, Z. Trend Prediction of FDI Based on the Intervention Model and ARIMA-GARCH-M Model. **AASRI Procedia**, v. 3, p. 387–393, 2012. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S221267161200220X>>. Acesso em: 25/2/2015.

SMOLA, A. J.; SCHÖLKOPF, B. A tutorial on support vector regression. **Statistics and Computing**, 1998.

SMOLA, A. J.; SCHÖLKOPF, B. A tutorial on support vector regression. **Statistics and Computing**, p. 199–222, 2004. Disponível em: <<http://eprints.pascal-network.org/archive/00002057/>>. .

SUJJAVIRIYASUP, T.; PITIRUEK, K. Hybrid ARIMA-Support Vector Machine Model for Agricultural Production Planning. **Applied Mathematical Sciences**, v. 7, n. 57, p.

2833–2840, 2013.

TAN, Z.; ZHANG, J.; WANG, J.; XU, J. Day-ahead electricity price forecasting using wavelet transform combined with ARIMA and GARCH models. **Applied Energy**, v. 87, n. 11, p. 3606–3610, 2010. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0306261910001807>>. Acesso em: 25/2/2015.

TAYLOR, J. S.; CRISTIANINI, N. **Kernel Methods for Pattern Analysis**. 2004.

TEIXEIRA JR, L. A. **Combinação Geométrica de Métodos Preditivos ; Aplicação à Previsão de Consumo Residencial Mensal de Energia Elétrica**, 2009. PUC-Rio.

TEIXEIRA JR, L. A. **Combinação SSA-Wavelet de Métodos Preditivos com Ajuste Numérico MINIMAX, na Geração de Previsões e de Cenários**, 2013. Puc-Rio.

TEIXEIRA JR, L. A.; DE MENEZES, M. L.; CASSIANO, K. M.; PESSANHA, J. F. M.; SOUZA, R. C. Residential Electricity Consumption Forecasting Using a Geometric Combination Approach. **International Journal of Energy and Statistics**, v. 01, n. 02, p. 113–125, 2013. Institute for International Energy Studies. Disponível em: <<http://www.worldscientific.com/doi/abs/10.1142/S2335680413500087>>. Acesso em: 7/3/2015.

TEIXEIRA JR, L. A.; PESSANHA, J. F. M.; MENEZES, M. L. DE; CASSIANO, K. M.; SOUZA, R. C. Redes neurais artificiais e decomposição wavelet na previsão da radiação solar direta. Congresso Latino-Iberoamericano de Investigación Operativa e Simpósio Brasileiro de Pesquisa Operacional. **Anais...** . p.1401–1412, 2012.

TEIXEIRA JR, L. A.; SOUZA, R. M.; MENEZES, L. M.; et al. Artificial Neural Network and Wavelet decomposition in the Forecast of Global Horizontal Solar Radiation. **Sobrapo**, v. 35, n. 1, p. 1–16, 2015.

TERUI, N.; VAN DIJK, H. K. Combined forecasts from linear and nonlinear time series models. **International Journal of Forecasting**, v. 18, n. 3, p. 421–438, 2002. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0169207001001200>>. Acesso em: 28/2/2015.

TIBSHIRANI, R. A comparison of some error estimates for neural network models. **Neural Computation**, v. 8, p. 152–163, 1996.

TSENG, F. M.; YU, H. C.; TZENG, G. H. Combining neural network model with

seasonal time series ARIMA model. **Technological Forecasting and Social Change**, v. 69, n. 12, p. 71–87, 2002.

VAPNIK, V. Universal learning technology: Support vector machines. **Nec Journal Of Advanced Technology**, v. 2, n. 2, p. 137–144, 2005. NEC Media Products. Disponível em: <<http://cat.inist.fr/?aModele=afficheN&cpsidt=16934264>>. .

VAPNIK, V. N. **The Nature of Statistical Learning Theory**. 1995.

VILLWOCK, R. **Técnicas de Agrupamento e de Hierarquização no Contexto de KDD - Aplicação a Dados Temporais de Instrumentação Geotécnica - Estrutura da Usina Hidrelétrica de Itaipu**, 2009. UNIVERSIDADE FEDERAL DO PARANÁ - UFPR PROGRAMA DE PÓS-GRADUAÇÃO EM MÉTODOS NUMÉRICOS EM ENGENHARIA - PPGMNE.

WALLIS, K. F. Combining forecasts : forty years later. **Applied Financial Economics**, p. 33–41, 2011. Disponível em: <<http://dx.doi.org/10.1080/09603107.2011.523179>>. .

YAO, X.; CROOK, J.; ANDREEVA, G. Support vector regression for loss given default modelling. **European Journal of Operational Research**, v. 240, n. 2, p. 528–538, 2015. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0377221714005463>>. Acesso em: 28/1/2015.

YU, P. S.; CHEN, S. T.; CHANG, I. F. Support vector regression for real-time flood stage forecasting. **Journal of Hydrology**, v. 328, n. 3-4, p. 704–716, 2006.

ZHANG, G. P. Time series forecasting using a hybrid ARIMA and neural network model. **Neurocomputing**, v. 50, p. 159–175, 2003. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0925231201007020>>. Acesso em: 8/1/2015.

ZHENG, F.; ZHONG, S. Time series forecasting using a hybrid RBF neural network and AR model based on binomial smoothing. **World Academy of Science Engineering and Technology**, p. 1125–1129, 2011.

ZHU, B.; WEI, Y. Carbon price forecasting with a novel hybrid ARIMA and least squares support vector machines methodology. **Omega**, v. 41, n. 3, p. 517–524, 2013. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0305048312001004>>. Acesso em: 6/2/2015.

ZHU, L.; LI, M. S.; WU, Q. H.; JIANG, L. Short-term natural gas demand prediction based on support vector regression with false neighbours filtered. **Energy**, v. 80, p. 428–436, 2015. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0360544214013553>>. Acesso em: 28/1/2015.

ZHU, L.; WANG, Y.; FAN, Q. MODWT-ARMA model for time series prediction. **Applied Mathematical Modelling**, v. 38, n. 5-6, p. 1859–1865, 2014. Elsevier Inc. Disponível em: <<http://dx.doi.org/10.1016/j.apm.2013.10.002>>. .